

BAB II

TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1 Tinjauan Pustaka

Dalam beberapa tahun terakhir, munculnya Jejaring Sosial *Online* telah menyebabkan munculnya berita sosial seperti iklan produk, berita politik, informasi selebriti, dll (Sahoo & Gupta, 2020). Beberapa jejaring sosial seperti Facebook, Instagram dan Twitter. Sayangnya, beberapa pengguna menggunakan cara yang tidak etis dengan menyebarkan berita palsu dalam berbagai media seperti teks, gambar, dan video. Sehingga, informasi terbaru yang muncul di jaringan sosial *online* diragukan dan dalam banyak kasus, menyesatkan pengguna lain. Berita palsu disebarkan dengan sengaja untuk menyesatkan pembaca agar mempercayai berita palsu. Oleh karena itu, dalam penelitian akan dilakukan deteksi berita palsu otomatis di lingkungan *chrome* yang dapat mendeteksi berita palsu di Facebook. Dalam penelitian yang dilakukan oleh (Ghinadya & Suyanto, 2020) dengan berita palsu menggunakan *Bidirectional Long Short Term Memori* (Bi-LSTM) dengan 5000 artikel berita dari FNC-1 menunjukkan bahwa metode yang diusulkan menghasilkan *F1-score* sebesar 24,23%.

Pada penelitian Soetrisno & Sofwan (2017) yang membahas terkait kebohongan yang disengaja yang dibuat untuk tampil sebagai kebenaran, atau sering disebut *hoax* (*hocus to trick*). Dengan menggunakan klasifikasi dan representasi vektor teks berdasarkan *Term Frequency* dan *Document Frequency* yang digunakan untuk membuat filter *hoax*. Untuk keperluan penelitian ini, *Machine Backing Vector* dan *Stochastic Slope Drop* dipilih di antara sejumlah teknik pengelompokan. *Supports Vector Machine* membagi vektor kata menggunakan fungsi linier, sedangkan *Stochastic Gradient Descent* (SGD) membagi vektor kata menggunakan fungsi *nonlinier*. Karena urutan teks berkualitas tinggi, yang mencakup kerangka kerja yang rumit, SVM dan SGD dipilih. Vektor fitur kata dapat dibagi menggunakan garis linear dan non-linear dengan Linear SVC dan SGD, dan setiap kata dalam artikel berita dapat

dimodelkan sebagai fitur. Lebih dari 100 situs *hoax* dan 100 situs *non-hoax* dipilih secara acak dari luar kumpulan data pelatihan, pengklasifikasi SGD dengan modifikasi mencapai akurasi 86%.

Kajian selanjutnya yang dilakukan oleh Kurniawan & Mustikasari (2019) menggunakan *Deep Learning* untuk mengidentifikasi *fake news* dan berita yang mengandung fakta dalam bahasa Indonesia. Metode CNN dan LSTM yang digunakan dalam penelitian. Pengumpulan data, *labeling*, *preprocessing*, *word embedding*, *splitting*, pembuatan model CNN dan LSTM, evaluasi model, pengujian data, dan membandingkan hasil evaluasi merupakan langkah-langkah dalam proses penelitian. Sebuah situs web bernama TurnbackHoax.id menawarkan berita faktual dan palsu. Ada total 1786 berita yang dikumpulkan, 984 di antaranya palsu dan 802 faktual. Dengan tingkat uji akurasi, presisi, dan recall sebesar 88% penelitian ini menunjukkan bahwa metode CNN dan LSTM berhasil diimplementasikan, sedangkan model LSTM mencapai tingkat uji akurasi, presisi, dan recall sebesar 83%. Disimpulkan bahwa metode CNN lebih unggul dari model metode LSTM berdasarkan evaluasi dan pengujian yang telah dilakukan. Menurut Kumar & Asthana (2020) menyimpulkan bahwa LSTM CNN + dua arah mencapai akurasi tertinggi 88.78%. Data yang di kumpulkan sebesar 1356 berita dari berbagai pengguna melalui Twitter dan sumber media seperti *PolitiFact* dan membuat beberapa kumpulan data untuk berita asli dan berita palsu.

Penelitian yang dilakukan oleh (Perdana dkk., 2020) membahas terkait berita *hoax* dengan menggunakan metode *Recurrent Neural Network* (RNN) serta variannya, *Long Short-Term Memory* (LSTM). Keakuratan hasilnya, yang lebih tinggi daripada metode pembelajaran mesin seperti *Multinomial Naive Bayes* dan *Rocchio* adalah 90%. Kemudian menurut (Nayoga dkk., 2021) melakukan penelitian yang berfokus pada *fake news*, dengan menggunakan *Deep Neural Network* (DNN), *Long Short-Term Memory* (LSTM), *Bidirectional LSTM* (BI-LSTM), *Gated Recurrent Unit* (GRU), *Bidirectional GRU* (BI-GRU), dan *1-Dimensional Convolutional Neural Network* (1D-

CNN) model, serta dua pengklasifikasi, disajikan dalam penelitian ini. Validitas berita berbahasa Indonesia dapat diprediksi dengan bantuan *Support Vector Machine* (SVM) dan *Naive Bayes*. Dalam tugas klasifikasi hasilnya menunjukkan bahwa model 1D-CNN mengungguli pengklasifikasi, dengan model DNN mencapai hasil terbaik. Meskipun 1D-CNN terkenal berkinerja lebih baik dalam pengenalan gambar dan visual, ID-CNN mencapai hasil tertinggi 90%. Penelitian oleh (Monti & Frasca, 2019), menggunakan sebuah novel otomatis model deteksi berita palsu berbasis *deep learning geometris*. Hasil penelitian menunjukkan bahwa struktur jaringan sosial dan propagasi adalah fitur penting yang memungkinkan akurasi tinggi sebesar 92,7%.

Berita palsu dapat membahayakan masyarakat Indonesia dari segi sosial dan politik. Melakukan kekerasan terhadap orang yang memiliki gangguan jiwa dan merusak reputasi politikus Indonesia saat pemilu adalah akibat dari berita palsu. Indonesia menempati peringkat ke-60 dari 61 negara peserta dalam studi "World's Most Literate Nations" tahun 2016 yang dilakukan oleh Central Connecticut University. Peningkatan ini menunjukkan literasi media Indonesia masih kurang memiliki kemampuan untuk menilai informasi secara kritis dan membedakan antara berita yang benar dan yang salah. Dalam penelitian ini, akan mengidentifikasi berita palsu dan membuat Augmentasi Data untuk Deteksi Berita Palsu menggunakan teknik *Convolutional Neural Network* (CNN). Performa model yang dibuat akan diuji dan dievaluasi menggunakan *Confusion Matrix*.

2.2 Landasan Teori

2.2.1 Berita Palsu / Berita Hoax

Berita palsu, juga dikenal sebagai *hoax*, adalah informasi yang terdistorsi yang ditulis dan dipublikasikan dengan tujuan untuk mendapatkan keuntungan finansial atau politik. Ini sering ditandai dengan tajuk utama yang sensasional, dilebih-lebihkan, atau secara terang-terangan menarik perhatian pembaca (Li, 2017).

Ungkapan "scam" berasal dari "hocus", dan itu menandakan "penipuan" (Prasetijo dkk., 2017). Ini adalah semacam tipu muslihat atau bahaya yang digunakan untuk membuat orang mengikuti sesuatu. Inspirasi fabrikasi itu sendiri bisa bersifat politis atau bisnis, dan dapat memiliki konsekuensi yang merugikan seperti materi dan, yang mengejutkan, hasil yang berbahaya. Kelompok orang yang ada akan lebih cepat terkena kata tipuan yang keluar lebih cepat. *Stochastic Gradient Descent* juga dipilih sebagai pengklasifikasi perbandingan karena ini juga berkinerja baik dengan data yang jarang dan berdimensi tinggi. SGD mengungguli presisi dan menjaga ingatan tinggi, yang berarti model itu berjalan dengan baik pada artikel prioritas tinggi selain sebagai "berita palsu" (Dyson, 2018). Penyebaran *hoax*, sayangnya juga didukung oleh media sosial yang mempercepat penyebaran berita tersebut. Permasalahan yang terjadi saat ini adalah penyebaran berita memang digunakan sebagai sarana untuk mencari uang agar *hoax* menyebar lebih cepat dan tidak terkendali. Setiap hari bisa saja ada website baru yang menyebarkan *hoax*, seperti banyak isu yang terjadi di dunia.

Hingga saat ini, berbagai langkah diambil dalam upaya untuk menentukan signifikansi tajuk, penerbit, dan artikel palsu. Selain itu, algoritma memiliki kompleksitas dan variasi yang beragam. Dalam artikel ini, file dalam format dataset (.csv) dari berbagai platform dan aplikasi turnbackhoax disertakan. Tabel 2.1 menampilkan sejumlah dataset, termasuk 15 data dengan dua kolom: 1 untuk positif dan 0 untuk negatif.

Tabel 2.1 Contoh Data Berita

No.	Tanggal	Teks	Label
1	24-Jun-20	Kadrunkalo lihat foto ini panas dingin. .	1
2	17-Jun-20	Halo, semua teman Facebook saya! Saya hanya ingin berbagi beberapa informasi dan memberi tahu Anda ke mana perginya uang saya. Kemarin, saya pergi ke acara promosi smartphone khusus JNE 2020 di bulan Juni, dan saya memesan smartphone VIVO V15 PRO hanya dengan harga Rp 900.000, saya tidak menyangka harganya hanya Rp. 900.000 Saya dapat membeli	1

		smartphone VIVO V15 PRO; bagi teman-teman facebook saya yang berminat atau ingin bergabung, kirimkan saja email ke WA ADMIN di 0823-7142-9.	
3	5-May-20	Lihatlah betapa siapnya mereka untuk memerintah bangsa ini!	1
4	24-Mar-20	Meski Italia memiliki fasilitas medis tercanggih, tak satu pun mampu mengendalikan corona. Awalnya, fenomena itu dianggap sebagai lelucon, dan sekarang presiden mereka menangis karena tidak cukup lahan untuk menguburkan 700 korban korona per hari (mungkin lebih dari 700 hari ini).	1
5	9-Jan-20	Polisi itu bodoh. Itu tidak cepat; tolong bantu saya dengan melihatnya.	1
6	24-Dec-19	Seolah-olah "polisi berkata, tunggu, giliranmu untuk orang-orang di sekitarmu biadab," Ham terdiam dalam ribuan bahasa sementara polisi China melecehkan seorang wanita Uyghur dan mencekik lehernya dengan kakinya.	1
7	13-Oct-19	Jokowi akhirnya siap turun. Saya harus siap untuk ini.	1
8	13-Jul-17	Istri pakar IT Hermansyah, Irina, disebut sebagai mantan PSK.	1
9	8-Mar-17	Menurut dugaan Alfian Tandjung, Nezar Patria adalah kader PKI yang setiap malam pergi ke istana setelah pukul delapan untuk rapat.	0
10	22-Mar-19	Kargo apa yang diangkat oleh truk semi-kontainer Paslon 01?	0
11	15-Agu-18	Itu terjadi secara kebetulan. Tidak terkait dengan vaksinasi. "Vaksin MR tidak menyebabkan penyakit ini dengan sendirinya," katanya.	0
12	8-Feb-18	Utk Kesekian kalinya terjadi Penganiayaan thdp Ulama2 di JaBar... ☹️ ☹️ Hr ini Ulama Bogor, Ust.sulaiman dibacok orang gila di bogor... ☹️ Umat ISLAM Rapatkan Barisan.. Always Waspada... 🙏 🙏 🙏 #Waspada #SaveUlama #HasbunallahWanimalWakiiil... 🙏 🙏	0
13	26-Jan-18	Bahaya Makan Rambutan Sambil Minum Teh Manis Sebabkan Penyumbatan Saluran Pernapasan	0
14	12-Feb-20	Akibat main game ular” yg lgi trending skrang, hati” Gaecees	1
15	21-Nov-19	Artikel tampan-news[dot]blogspot[dot]com menampilkan artikel dengan judul Percuma Dilaporkan,	1

		PDIP Sebut Sukmawati Tidak Bisa Ditahan Karena Dia Orang “Kuat” yang di awal artikel ditulis {MERDEKAIND}.	
--	--	--	--

2.2.2 Artificial Intelligence

Sebuah metode untuk memecahkan masalah dengan meniru kecerdasan makhluk hidup dan benda mati disebut kecerdasan buatan (Vasiljeva dkk., 2017). Selama sepuluh tahun terakhir, AI atau perkembangan teknologi informasi dan komunikasi menjadi perhatian. Beberapa dari banyak industri yang memanfaatkan AI termasuk sektor pemerintah, manufaktur, jasa, dan perbankan. Di sejumlah negara, khususnya di sektor industri, penggunaan AI sudah mencapai hampir 56 persen (Vasiljeva dkk., 2017).

Menurut penelitian, AI pertama kali diterapkan di Eropa dan Amerika Serikat. Negara tambahan yang sering berpartisipasi dalam penelitian teknologi AI adalah China dan Amerika Serikat. Selain berurusan dengan robot, AI bertujuan untuk memahami sifat pemikiran dan perilaku cerdas dengan memanfaatkan komputer sebagai perangkat eksperimental. Kemampuan untuk menghemat waktu dan meningkatkan kualitas layanan adalah dua keuntungan menggunakan AI. Karena investasi besar yang diperlukan dan kemungkinan pengurangan tenaga kerja, yang dapat mengakibatkan peningkatan pengangguran, penerapan AI menghadapi banyak tantangan di negara berkembang (Vasiljeva dkk., 2017).

Pembuatan permainan catur atau backgammon, menyelesaikan persamaan integral, dan memodifikasi persamaan tampaknya merupakan tugas yang sulit untuk AI, tetapi informatika tidak menghadapi tantangan ini. Namun, dalam informatika, sulit bagi manusia untuk mendemonstrasikan kecerdasan melalui aktivitas seperti sepak bola dan mengenali wajah dan objek. Ada tiga pendekatan berbasis AI:

1. Sistem FL yang tidak kaku dibuat dengan menggunakan *fuzzy logic* (FL), yang digunakan oleh sistem untuk mengubah kebiasaan makhluk hidup saat

mengambil keputusan untuk menghasilkan keputusan yang tidak kaku 0 atau 1. Sistem pengereman kereta di Jepang adalah salah satu penerapan sistem FL.

2. Untuk memecahkan masalah, komputasi evolusioner digunakan untuk mewujudkan rencana evolusioner dengan sejumlah besar orang dan menawarkan ujian untuk memilih yang terbaik untuk menciptakan generasi berikutnya. *Particle Swarm Optimization* (PSO), yang meniru kumpulan hewan seperti burung dan ikan untuk mencari mangsa, *Simulated Annealing*, yang meniru bagaimana logam ditempa, dan banyak contoh lainnya adalah contoh algoritma yang menggunakan konsep mutasi dan persilangan.
3. Metode yang paling banyak digunakan adalah *Machine Learning* (ML) yang digunakan untuk meniru atau menggantikan perilaku manusia.

Sebagian besar waktu, AI digunakan dalam robot. Robot adalah mesin yang dibuat untuk melakukan berbagai tugas tanpa bantuan manusia. Karena begitu banyak kegiatan dan layanan di tempat kerja dilakukan dengan sistem komputerisasi, kecerdasan buatan memainkan peran penting dalam kehidupan manusia. Selain itu, AI berguna untuk pengembangan perangkat lunak, memungkinkannya untuk maju dan berkembang (Munawar dkk., 2019).

AI didefinisikan dengan baik di lingkungan tertentu melalui penggunaan pembelajaran mesin, penalaran, pemrosesan statistik, atau masalah penargetan yang biasanya memerlukan intervensi manusia. AI secara otomatis diprogram untuk melakukan tugas tertentu. Tanpa desain ulang, domain tidak dapat digunakan dengan AI. Karena dapat memecahkan masalah di lingkungan yang menghasilkan informasi, AI berhasil digunakan di berbagai industri (Wright & Schultz, 2018). AI di berbagai bidang, antara lain:

1. Sektor bioinformatika komputasi kinerja tinggi atau *High Performance Computing* (HPC), yang memudahkan pekerjaan di bidang bioinformatika. Bioinformatika adalah hasil penggabungan teknologi informasi dan biologi.

Unit Pemrosesan Grafik (GPU) adalah metode yang efektif untuk menyelesaikan kasus dalam bioinformatika. Namun, karena lebih cepat, lebih hemat biaya, dan memungkinkan distribusi perangkat lunak yang tepat, metode pengelompokan lebih banyak digunakan. (Rukmayuninda Ririh dkk., 2020).

2. Teknologi *Big Data* sering dimanfaatkan oleh instansi pemerintah untuk meningkatkan pelayanan publik. *Big data* dapat digunakan untuk membangun kota pintar. Teknologi *Big Data* telah dimanfaatkan oleh sejumlah institusi selain Lembaga Kebijakan Pengadaan Barang/Jasa Pemerintah (LKPP), Direktorat Jenderal Pajak, Kementerian Keuangan, dan Badan Informasi Geospasial (BIG) (Rukmayuninda Ririh dkk., 2020).

2.2.3 *Machine Learning*

Suatu pendekatan dalam AI yang dikenal sebagai pembelajaran mesin sering digunakan untuk menggantikan perilaku manusia dalam pemecahan masalah. ML meniru proses pembelajaran dan generalisasi manusia. Klasifikasi dan prediksi adalah dua aplikasi utama ML (Vasiljeva dkk., 2017). Sedangkan (Wright & Schultz, 2018) ML merupakan perangkat lunak yang belajar dari pengalaman yang sudah ada. Semakin banyak data yang tersedia maka kinerja program komputer semakin baik. ML akan mempelajari pola dan menghasilkan kecerdasan buatan untuk data yang baru dimasukkan.

Pada ML terdapat proses pelatihan atau *training* dengan membutuhkan data untuk dipelajari (data *training*). Metode yang digunakan dalam ML adalah klasifikasi yang berguna untuk mengklasifikasikan objek berdasarkan ciri-ciri tertentu. Terdapat tiga metode dalam *training* ML, secara eksplisit Mendukung Pembelajaran, Pembelajaran Tunggal, dan Pembelajaran Teratur.

1. Instruksi yang Diawasi

Pembelajaran yang Diatur adalah bersiap untuk menggunakan informasi yang ditandai untuk mengatasi masalah sulit dalam sistem sensorik palsu.

diawasi lebih sering digunakan dalam tugas klasifikasi dan regresi (Mitchell, 1997).

2. *Pendidikan Tanpa Pengawasan*

Pelatihan dengan pola pada data yang belum pernah terlihat sebelumnya dikenal dengan *unsupervised learning*. Pengelompokan dan penemuan pola tersembunyi dalam data input yang tidak berlabel adalah dua penerapannya (Mitchell, 1997).

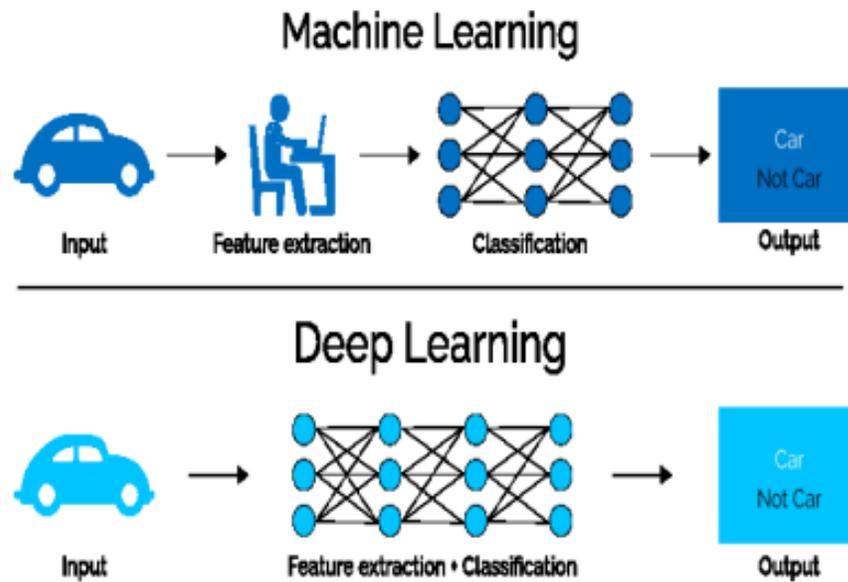
3. Belajar dengan penguatan

Pelatihan yang dikenal sebagai pembelajaran penguatan memerlukan perolehan informasi, berinteraksi dengan lingkungan, dan menerima umpan balik positif atau negatif untuk meningkatkan kapasitas seseorang untuk belajar dari kesalahan. Ini biasanya digunakan di mobil otomatis dan permainan logika.

2.2.4 Deep Learning

Sebuah teknik yang dikenal sebagai pembelajaran mendalam memanfaatkan Jaringan Syaraf Tiruan (JST) multilayer. Jaringan *neuron* yang sangat rumit yang sebanding dengan otak manusia terbentuk ketika *neuron* terhubung satu sama lain. Beberapa transformasi non-linear digunakan dalam *Deep Learning*, AI dan pendekatan pembelajaran mesin (Primartha, 2018).

Inovasi pembelajaran yang mendalam memisahkan ide-ide kompleks menjadi pengaturan ide yang tidak terlalu sulit. Melibatkan informasi sebagai informasi, menanganinya melalui berbagai lapisan rahasia, dan kemudian menentukan nilai hasil melalui perubahan informasi informasi yang tidak langsung, pembelajaran mendalam adalah strategi untuk menyelesaikan organisasi otak palsu (Primartha, 2018).



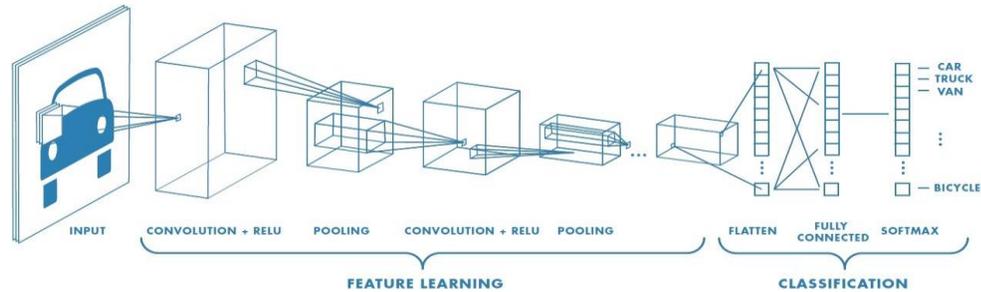
Gambar 2.1 Perbedaan *machine learning* dengan deep learning (Nikoskinen, 2015)

Perbedaan ekstraksi fitur antara ML dan *deep learning* digambarkan pada Gambar 2.1. Langkah klasifikasi dalam pembelajaran mendalam dapat dikombinasikan dengan langkah ekstraksi fitur dalam pembelajaran mesin. *Deep Neural Networks* (DNN), *Deep Believe Networks* (DBN), *Deep Convolutional Neural Networks* (DCNN), dan *Deep Recurrent Neural Networks* (DRNN) adalah empat arsitektur pembelajaran yang mendalam. Proses DBN biasanya dilakukan dalam satu arah *feed-forward* ke DBN dengan lapisan tersembunyi berupa *Restricted Boltzman Machine* (RBM). DNN cocok untuk data *multivariat* dengan banyak *input neuron*. DCNN, di sisi lain, menggunakan lapisan padat selain lapisan maks dan kumpulan, yang lebih cocok untuk klasifikasi gambar. DRNN lebih cocok untuk pengenalan teks, ucapan, bahasa, atau data dengan tipe deret waktu (Nikoskinen, 2015).

2.2.5 Metode CNN

Convolutional Brain Organization (CNN) adalah *Multi-facet Perceptron* (MLP) yang dibuat dan ditujukan untuk penanganan informasi dua lapis. Karena dapat diterapkan pada data citra dan memiliki kedalaman yang tinggi, CNN termasuk dalam metode deep learning. Menggunakan pembelajaran terawasi, *Convolutional Neural Networks* dapat digunakan untuk mengklasifikasikan data gambar berlabel. CNN bekerja dengan melatih data dan menentukan variabel. Strategi ini memiliki tujuan untuk memilah informasi menjadi informasi yang ada. Karena digambarkan secara dua dimensi, maka setiap *neuron* pada *Convolutional Neural Network* cocok untuk pemrosesan input berbasis citra (Hermawati & Zai, 2021).

Pada Gambar 2.2, kontribusi *Convolutional Brain Organization* adalah informasi gambar, yang memainkan peran utama dalam menyoroti pembelajaran, khususnya konvolusi. Dengan menggunakan bagian tersebut, konvolusi dilakukan berdasarkan ukuran yang telah ditentukan sebelumnya. Kemampuan inisiasi dari *Redressed Straight Unit* (ReLU) akan menentukan hasil dari tahap ini. Hasil dari tahap sebelumnya akan menjadi dasar untuk prosedur pooling. Tergantung pada aktivitas pooling yang digunakan, gambar yang lebih kecil akan dihasilkan oleh sistem pooling. Data harus dikategorikan pada langkah kedua. Elemen lapisan pesanan terdiri dari lapisan yang benar-benar terkait yang terbuat dari neuron yang benar-benar terkait dengan berbagai lapisan. *Output* lapisan ekstraksi fitur gambar diubah menjadi vektor dan digunakan sebagai input lapisan. Lapisan hasil yang terhubung ke lapisan *output softmax* akan memberikan nilai probabilitas. Kemungkinan bahwa data input milik kelas tertentu di setiap kelas atau *vektor* ditunjukkan oleh nilai masing-masing (Guidici & Clark, 2017).



Gambar 2.2 Arsitektur CNN (Nugroho dkk., 2020)

Setelah itu, akan ditentukan kategori nilai akurasi hasil klasifikasi sebagai berikut:

- Pesanan fantastis mendapat nilai ketepatan 0,90-1,00
- Penataan yang bagus mendapatkan nilai presisi 0,80-0,90.
- Karakterisasi fair mendapatkan nilai presisi 0,70-0,80.
- Akurasi klasifikasi yang buruk berkisar antara 0,60-0,70.
- Kegagalan menghasilkan nilai akurasi antara 0,5 dan 0,60..

2.2.6 Operasi Konvolusi

Kernel dikalikan dengan input data selama operasi konvolusi. Sebelum diproses, semua nilai input dan kernel harus disimpan, sehingga nilai input dan kernel dinyatakan 0 untuk setiap komponen, kecuali komponen yang disimpan sebelumnya. Misalnya, input x adalah data yang berbentuk array multidimensi, dan kernel w adalah parameter yang digunakan dalam bentuk array multidimensi. Hasil dari penjumlahan adalah banyaknya masukan *array* bukan penjumlahan tak berhingga. Operasi konvolusi akan menghasilkan *feature map* (Darmanto, 2019). Untuk mengolah citra, operasi konvolusi dapat diketahui dengan menggerakkan *kernel W* yang memiliki ukuran $m \times n$ pada citra I yang memiliki ukuran $i \times j$. Lalu, hasilnya adalah jumlah dari nilai citra yang dikalikan dengan *kernel* tersebut (Ilahiyah & Nilogiri, 2018). Persamaan yang digunakan untuk

menghitung operasi konvolusi citra $I \in R^{w \times h}$, dengan kernel $W \in R^{P \times Q}$ adalah sebagai berikut:

$$(I * W)(i, j) = \sum_{m=0}^{P-1} \sum_{n=0}^{Q-1} I[i + m, j + n] W[m, n] \quad (2.1)$$

$$i = 0, \dots, H - 1; j = 0, \dots, W - 1$$

Keterangan:

$(I * W)(i, j)$ = *feature map*

I = matriks *input*

W = matriks *kernel*

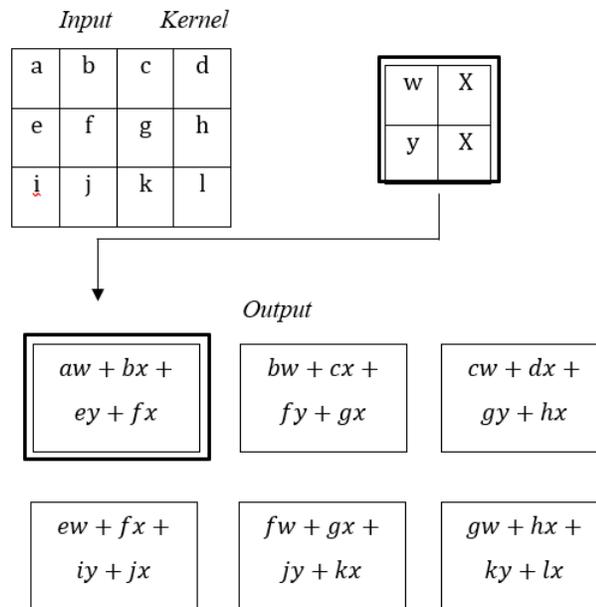
m, n = jumlah ukuran *kernel*

W, H = *width, height*

Operasi konvolusi menghasilkan citra yang lebih kecil dari citra awal. Ukuran citra akhir akan mengecil menjadi 32×32 *pixel* jika citra awal memiliki ukuran 3×3 , piksel dan operasi konvolusi dengan ukuran kernel $(32 - 3 + 1) \times (32 - 3 + 1) = 30 \times 30$. Persamaan untuk mencari ukuran hasil konvolusi adalah sebagai berikut:

$$Ukuran_{hasilkonvolusi} = Ukuran_{awal} - Filtersize + 1 \quad (2.2)$$

SEKOLAH PASCASARJANA



Gambar 2.3 Ilustrasi operasi konvolusi (Ilahiyah & Nilogiri, 2018)

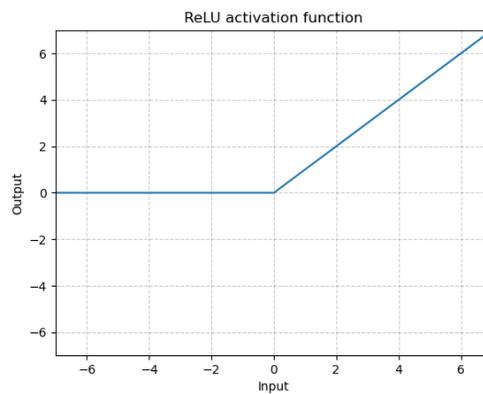
Operasi konvolusi pada citra yang menggunakan array dua dimensi I dan bobot pada kernel W (dua dimensi) digambarkan pada gambar di atas. Gambar memiliki ukuran dalam gambar ini 4×3 kernel dengan ukuran yang berbelit-belit 2×2 . Gambar yang berbelit-belit menghasilkan ukuran 3×2 . Komponen utama dalam gambar hasil belitan adalah jumlah porsi muatan yang digandakan dengan nilai gambar yang dimaksud.

2.2.6.1 Fungsi Aktivasi

Kemampuan *enactment* adalah kemampuan yang tugasnya menentukan aksi suatu *neuron* dengan mengubah kondisi lurus dari kombinasi data dan beban bit menjadi kondisi tidak langsung. Fungsi aktivasi diubah karena harus berupa persamaan nonlinier yang dapat diubah secara terus menerus. Satuan linear yang diperbaiki (ReLU), fungsi tangen *hiperbolik*, dan fungsi sigmoi adalah contoh populer dari fungsi aktivasi. ReLU adalah salah satu fungsi aktivasi yang

terpopuler karena banyak digunakan. ReLU dapat memberikan hasil performa dan generalisasi yang jauh lebih baik dibandingkan fungsi sigmoid dan Tanh (Ilahiyah & Nilogiri, 2018). Persamaan Fungsi ReLU dapat dirumuskan sebagai berikut:

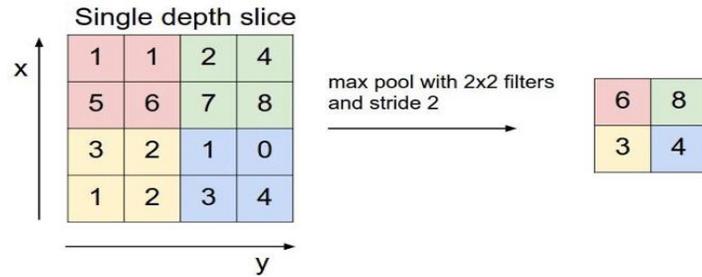
$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{jika } x_i > 0 \\ 0, & \text{jika } x_i \leq 0 \end{cases} \quad (2.3)$$



Gambar 2.4 Plot Distribusi Fungsi ReLU (Brownlee, 2019)

2.2.6.2 Operasi Pooling

Dengan mengurangi matriks, operasi pooling dan subsampling mengurangi ukuran matriks. Jaringan Syaraf Konvolusional biasanya menyertakan lapisan penyatuan secara berurutan setelah beberapa lapisan konvolusional. *Max pooling* dan *average pooling* adalah dua metode pooling yang paling sering digunakan. Penyatuan rata-rata mengambil nilai rata-rata, sedangkan penyatuan maks mengambil nilai maksimum (Bejiga, dkk., 2017). Operasi *max pooling* 2×2 pada Ilustrasi 2.5 akan terlihat seperti berikut.

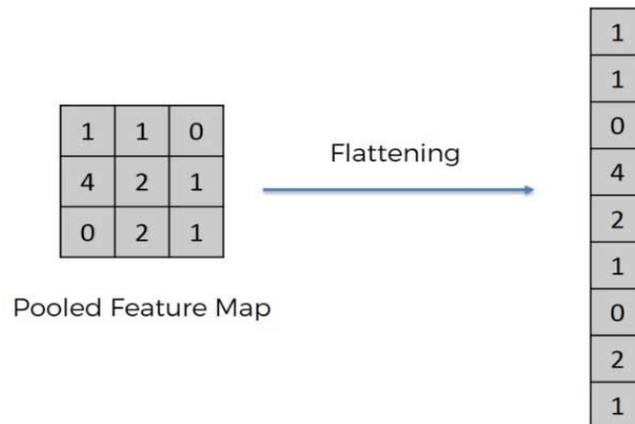


Gambar 2.5 Ilustrasi operasi *pooling*

Proses *pooling* akan memperkecil ukuran dimensi dari sebuah matriks dibandingkan dengan ukuran awal. *Feature map* didapatkan dengan cara melakukan beberapa kali operasi konvolusi dan *pooling* sampai didapatkan ukuran yang diinginkan. *Feature map* yang dihasilkan akan menjadi masukan untuk *fully connected layer*.

2.2.6.3 Flattening

Definisi perataan adalah transformasi kumpulan data dari array dua dimensi menjadi satu vektor data satu dimensi. Tujuan dilakukan konversi agar fitur yang telah dikumpulkan dapat masuk ke tahapan input *Fully Connected Layer* (Kurnia & Wibowo, 2021).



Gambar 2.6 Ilustrasi *Flattening* (Kurnia & Wibowo, 2021)

2.2.6.4 Fully Connected Layer

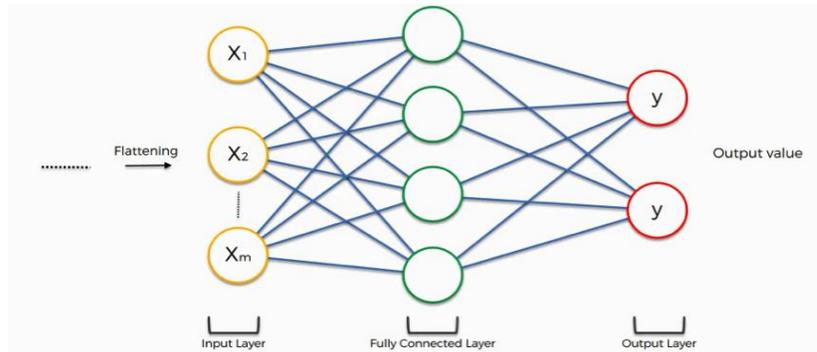
Lapisan yang berisi neuron dari lapisan sebelumnya dan akan terhubung ke setiap neuron di lapisan berikutnya disebut lapisan yang terhubung sepenuhnya. Ini setara dengan organisasi otak palsu biasa. Dengan mengubah aktivasi di lapisan sebelumnya menjadi data satu dimensi, aktivasi lapisan dapat dihubungkan ke semua neuron di lapisan yang terhubung sepenuhnya. Sehingga data dapat ditransformasikan dari matriks ke vektor menggunakan proses perataan (Albelwi & Mahmood, 2017). Proses lapisan yang terhubung sepenuhnya menggunakan persamaan berikut:

$$\hat{y}_k = w_0 + \sum_{i=0}^n x_i w_{i,k} ; k = 0,1,2, \dots, t \quad (2.4)$$

Keterangan:

\hat{y}	= <i>output fully conncted layer</i>
w_0	= bias
n	= Jumlah data pada setiap unit
x	= nilai <i>input</i> dalam <i>flatten</i>
w	= bobot
t	= Jumlah target pada <i>fully conncted layer</i>

Kelebihan dari *Convolutional Neural Network* jika menggunakan lebih dari satu dimensi adalah akan mempengaruhi keseluruhan ukuran suatu objek (Djerriri dkk., 2018).



Gambar 2.7 Ilustrasi *Fully Connected Layer* (Kurnia & Wibowo, 2021)

2.2.6.5 Softmax

Fungsi *softmax activation*, yang dilakukan pada output layer selama tahap *Fully Connected/classification* dan menghasilkan nilai antara 0 dan 1, akan digunakan pada kasus klasifikasi lebih dari dua kelas (*multi-class*). Proses aktivasi softmax bertujuan untuk mengklasifikasikan citra masukan yang telah diproses sebelumnya dengan menentukan probabilitas pada masing-masing kelas (Kurnia & Wibowo, 2021).

2.2.7 Augmentasi Data

Ekspansi informasi adalah suatu sistem yang dapat memperluas ragam informasi yang ada untuk dijadikan model dalam menyusun model, tanpa mengumpulkan informasi baru. Strategi peningkatan informasi yang digunakan untuk menyiapkan jaringan otak besar adalah bantalan, pembalikan level, dan pemangkasan. Namun, umumnya pendekatan hanya menggunakan tipe augmentasi dasar dalam pelatihan jaringan *neural* (Sanjaya & Ayub, 2020).

2.2.7.1 Augmentasi Data di NLP

Teknik augmentasi dalam pemrosesan gambar sangat populer (Perez & Wang, 2017), namun untuk teknik augmentasi data teks dalam aplikasi NLP masih relatif kurang digunakan, sebagian besar karena kompleksitas bahasa alami. Namun, baru-baru ini, metode untuk memperluas data pelatihan tekstual untuk tugas NLP telah menjadi subjek dari beberapa penelitian (Feng, dkk, 2021). Secara umum, metode

augmentasi dalam NLP dapat dibagi menjadi empat kelompok berdasarkan tingkat dimana prosedur augmentasi bekerja. Augmentasi level karakter didasarkan pada penambahan *noise* ke sampel pelatihan (misalnya, mengganti huruf) pada level karakter. Pendekatan seperti itu dapat digunakan untuk mensimulasikan dalam teks (misalnya, kesalahan ejaan), yang umum dalam teks tertulis. Model yang dilatih pada data tingkat karakter yang disempurnakan harus lebih cocok untuk tugas pemrosesan teks dalam beberapa hal tertentu misalnya, klasifikasi teks dari jejaring sosial (Belinkov & Bisk, 2017). Augmentasi tingkat kata didasarkan pada penambahan *noise* atau penggantian kata. Sangat umum yaitu pendekatan berbasis kosakata, dimana penggantian didasarkan pada *leksikon* yang berbeda. Salah satu yang paling sering digunakan adalah *Wordnet* (Feng, dkk, 2021).

2.2.7.2 Easy Data Augmentation (EDA)

Teknik augmentasi tingkat kata yang sangat populer adalah (EDA). EDA terdiri dari teknik augmentasi yang dikembangkan dan dievaluasi (Wei & Zou, 2019). Penelitian (Liesting dkk., 2021) menyebutkan bahwa EDA lebih unggul dibandingkan beberapa metode augmentasi lainnya dan memberikan peningkatan pada performa model yang digunakan untuk task tersebut.

Kumpulan metode EDA menggunakan pendekatan tradisional yang langsung untuk meningkatkan volume data. Teknik-teknik ini menciptakan data baru sehingga makna dan struktur gramatikal dari data asli dipertahankan. EDA terdiri dari empat metode berikut: penghapusan acak (RD), penyisipan acak (RI), pertukaran acak (RS), penggantian sinonim (SR).

1. *Synonym Replacement (SR)*

Pengganti sinonim (SR), metode ini membuat sampel baru dari dokumen teks dengan mengganti kata-kata yang cocok dari teks dengan sinonimnya yang mempertahankan makna teks. Pengguna perlu memberikan parameter n , yang menentukan berapa banyak kata yang diganti dengan sinonimnya dalam

kalimat yang diberikan. Pengguna juga harus fokus pada pemilihan kata yang tepat dan sinonim yang tepat yang tidak mengubah arti teks.

2. *Random Insertion (RI)*

Penyisipan acak metode ini bekerja dengan sinonim kata-kata yang dipilih seperti pada metode sebelumnya. Namun, perbedaannya adalah n sinonim dari kata-kata yang dipilih secara acak dimasukkan pada posisi yang berbeda dalam teks. Penyisipan sinonim secara acak dari kata-kata tertentu dari teks, sebagai lawan dari penggantian sinonim, bisa lebih relevan dengan konteks tertentu, karena mempertahankan evaluasi asli teks. Metode ini ditentukan oleh jumlah kata penuh makna yang sinonimnya disisipkan secara acak pada posisi tertentu.

3. *Random Swap (RS)*

Pertukaran acak, tidak seperti metode sebelumnya, metode ini tidak menggunakan sinonim untuk membuat sampel baru. Metode ini bertujuan untuk memilih dua kata acak yang bertukar posisi dalam teks. Pengguna menentukan parameter, yang menentukan berapa banyak pasangan kata yang harus bertukar posisi dalam teks. Metode ini dapat membantu model menjadi lebih kuat. Namun, jumlah kata yang dipertukarkan yang sangat tinggi dapat memperburuk model karena perubahan makna teks

4. *Random Deletion (RD)*

Penghapusan acak, tujuan dari metode ini adalah untuk secara acak menghapus kata-kata dalam teks dengan probabilitas tertentu yang ditentukan oleh parameter. Penting untuk memilih probabilitas dengan tepat agar kita tidak menghapus banyak kata dari teks.