



IMPLEMENTASI ALGORITMA PEMBELAJARAN BACK PROPAGATION UNTUK KLASIFIKASI TWEET RESOLUSI

LINGGAR JUWITA HANDAYANI

NRP 5112 100 031

Dosen Pembimbing

Diana Purwitasari, S.Kom., M.Sc.

Dini Adni Navastara, S.Kom., M.Sc.



ITS

Institut
Teknologi
Sepuluh Nopember

No	Tweet
1	#NewYearsResolution Stop doubting myself
2	#NewYearsResolution to eat buy and eat environmentally responsible. buy for local businesses and eat a plant based diet. #eatclean2015
3	Adventures. I'm ready for more of those. #NewYearsResolution
4	#NewYearsResolution will be moving to @ExploreGeorgia #Altanta going to school and becoming a hair dresser or a actor!
5	I'm going to stop being honest and start telling people whatever they want to hear. So much easier. #NewYearsResolution
6	@jeffreymarshnow My New Years Resolution: Be brave and speak up about issues that matter! #NewYearsResolution
7	"New Years Resolution Save Money don't Spend Money"
8	New Years resolution: more brunch.



LATAR BELAKANG

- Pengguna social media, dalam kasus ini Twitter, sering berbagi pengalaman keseharian.
- Jumlah *tweet* meningkat pesat menjelang tahun baru. Dan *tweet* resolusi mendominasi pada awal tahun.
- Awal tahun merupakan waktu yang bagus untuk menyusun strategi bisnis, baik penyedia barang dan jasa.
- Dari *tweet-tweet* resolusi, dilakukan klasifikasi untuk mengetahui keinginan pengguna, sebagai konsumen.



RUMUSAN MASALAH


- Bagaimana melakukan klasifikasi teks tweet ke dalam kategori yang telah ditentukan?
- Bagaimana mengekstraksi fitur teks berdasarkan kemunculan kata dalam dokumen?
- Bagaimana melakukan prediksi kategori teks tweet dengan model jaringan yang telah ada?



BATASAN MASALAH

- Sistem dibangun berbasis desktop, dengan basis data dan bahasa pemrograman C# serta kerangka kerja .NET.
- Data tweet resolusi yang digunakan adalah dataset tweet resolusi Tahun Baru 2015.
- Data tweet resolusi diambil berdasarkan penggunaan #newyearsresolution pada teks tweet.
- Data tweet resolusi yang akan diproses adalah teks Bahasa Inggris.
- Data masukan tweet resolusi telah dikompilasi dalam bentuk dokumen excel spreadsheet, dengan tipe berkas Microsoft Excel (ekstensi .xls atau .xlxs).
- Model Jaringan Saraf Tiruan yang digunakan adalah jenis Multi Layer Perceptron dengan satu hidden layer.
- Kelas tweet terdiri dari enam kelas, di antaranya, Career & Education, Finance, Health & Fitness, Personal Growth, Recreation & Leisure, dan Relationship.

DIAGRAM ALIR SISTEM





ITS

Institut
Teknologi
Sepuluh Nopember

TAHAP PRAPOSES TEKS

No	Input	Case Folding	Tokenizing	Filtering
1	<i>Self improvement!.. Mentally, physically, and financially. #NewYearsResolution</i>	<i>self improvement!.. mentally, physically, and financially. #newyearsresolution</i>	<i>self improvement mentally physically and financially newyearsresolution</i>	<i>self improvement mentally physically financially</i>
2	<i>social media purging &gt; #NewYearsResolution</i>	<i>social media purging &gt; #newyearsresolution</i>	<i>social media purgung gt newyearsresolution</i>	<i>social media purgung</i>
3	<i>to actually work out and not be lazy about it #NewYearsResolution</i>	<i>to actually work out and to not be lazy about it #newyearsresolution</i>	<i>to actually work out and not be lazy about it newyearsresolution</i>	<i>work lazy</i>

PEMBOBOTAN FITUR TEKS


$$tf_i(d_j) = \frac{freq_i(d_j)}{\sum_{i=1}^k freq_i(d_j)} \quad (2.1)$$


$$idf_i = \log \frac{|D|}{|\{d: t_i \in d\}|} \quad (2.2)$$

$$(tf - idf)_{ij} = tf_i(d_j) \cdot idf_i \quad (2.3)$$

Di mana,


- $freq_i(d_j)$ adalah frekuensi *term ke- i* dalam dokumen ke- *j*.
- $\sum_{i=1}^k freq_i(d_j)$ adalah jumlah *term* pada dokumen ke- *j*.
- $|D|$ adalah jumlah dokumen dalam *corpus*.
- $|\{d: t_i \in d\}|$ adalah dokumen yang mengandung *term ke- i*.








TAMPILAN ANTARMUKA PENGGUNA





ANTARMUKA PENGGUNA





SKENARIO UJI COBA

- Hasil akurasi berdasarkan variasi nilai learning rate.

Tujuan skenario ini adalah untuk mengetahui pengaruh nilai learning rate terhadap nilai akurasi.

- Hasil akurasi berdasarkan variasi jumlah neuron pada hidden layer.

Tujuan skenario ini adalah untuk mengetahui pengaruh jumlah neuron pada hidden layer terhadap nilai akurasi.

- Hasil akurasi berdasarkan variasi maksimum nilai epoch.

Tujuan skenario ini adalah untuk mengetahui pengaruh nilai epoch terhadap nilai akurasi.

- Hasil akurasi berdasarkan variasi persentase data pada metode hold-out.

Tujuan skenario ini adalah untuk mengetahui pengaruh perbandingan data training dan data testing terhadap nilai akurasi.

- Hasil akurasi menggunakan kombinasi neuron, epoch, dan learning rate dari skenario uji coba ke-1, ke-2, dan ke-3.

Tujuan skenario ini adalah untuk mengetahui seberapa besar perubahan akurasi terhadap perubahan nilai learning rate menjadi 0,10 dan 0,05; serta pembagian data set dengan persentase 10% dan 20%.



DATA UJI COBA

No	Tweet	Topik	Kelas
1	#NewYearsResolution Stop doubting myself	Be more positive	Personal Growth
2	#NewYearsResolution to eat buy and eat environmentally responsible. buy for local businesses and eat a plant based diet. #eatclean2015	Eat healthier	Health & Fitness
3	Adventures. I'm ready for more of those. #NewYearsResolution	Take a trip	Recreation & Leisure
4	#NewYearsResolution will be moving to @ExploreGeorgia #Altanta going to school and becoming a hair dresser or a actor!	Get dream job	Career & Education
5	I'm going to stop being honest and start telling people whatever they want to hear. So much easier. #NewYearsResolution	Be better at keeping in touch with loved ones or friends	Relationship
6	@jeffreymarshnow My New Years Resolution: Be brave and speak up about issues that matter! #NewYearsResolution	Be more confident	Personal Growth
7	"New Years Resolution Save Money don't Spend Money"	Save money	Finance
8	New Years resolution: more brunch.	Eat more	Health & Fitness


Uji Coba dan Analisa Nilai *Learning Rate*

No	Data	Fitur	Learning Rate	MSE	Akurasi (%)		Lama Train (s)
					Train	Test	
1	1056	1990	0,01	0,82	0,22	0,14	78
2			0,05	0,06	0,96	0,50	80
3			0,10	0,02	0,97	0,47	77
4			0,25	0,03	0,95	0,45	97
5	3914	4551	0,01	0,35	0,70	0,54	3328
6			0,05	0,07	0,94	0,55	3497
7			0,10	0,06	0,94	0,57	2959
8			0,25	0,62	0,59	0,41	3073

- Nilai MSE paling rendah dimiliki oleh *learning rate* 0,05.
- Perubahan *learning rate* dari 0,01 hingga 0,10 menunjukkan peningkatan akurasi. Namun pada *learning rate* 0,25, akurasi menurun.
- Sistem klasifikasi memiliki nilai akurasi pada nilai *learning rate* 0,10.

Uji Coba dan Analisa Nilai Learning Rate

Hasil Uji Coba Variasi Nilai Learning Rate






Uji Coba dan Analisa Jumlah Neuron

No	Data	Fitur	Neuron	MSE	Akurasi (%)		Lama Train (s)
					Train	Test	
1	1056	1990	1%	0,58	0,54	0,34	4
2			1%	0,02	0,97	0,47	77
3			10%	0,01	0,95	0,50	2002
4	3914	4551	1%	0,08	0,93	0,57	169
5			1%	0,06	0,94	0,57	2959
6			10%	0,06	0,94	0,57	61375

- Hidden layer dengan neuron sejumlah 1% dari neuron pada input layer belum cukup untuk menghasilkan akurasi yang tinggi.
- Mulai uji coba dengan neuron 1%, nilai akurasi mulai stabil dan cukup tinggi.

Uji Coba dan Analisa Jumlah Neuron




- Lama waktu *training* bertambah seiring jumlah *neuron* pada *hidden layer*. 1% dianggap terbaik dengan mempertimbangkan akurasi.

Uji Coba dan Analisa Maksimum Epoch

No	Data	Fitur	Epoch	MSE	Akurasi (%)		Lama Train (s)
					Train	Test	
1	1056	1990	1	0,82	0,17	0,11	6
2			5	0,14	0,92	0,45	27
3			10	0,02	0,97	0,47	77
4			50	0,01	0,97	0,46	418
5			100	0,01	0,97	0,42	1276
6	3914	4551	1	0,51	0,61	0,52	406
7			5	0,11	0,92	0,54	1624
8			10	0,06	0,94	0,57	2959
9			50	0,06	0,94	0,57	16063
10			100	0,06	0,94	0,55	49035

- Maksimum epoch tidak memengaruhi akurasi.
- Namun, dengan epoch terlalu kecil, akurasi juga akan berpengaruh. Karena sistem tidak memiliki cukup kesempatan untuk mempelajari data.

Uji Coba dan Analisa Maksimum Epoch



- Variasi maksimum epoch mempengaruhi lama waktu *training*. Semakin banyak *epoch*, semakin lama waktu *training*.



Uji Coba dan Analisa Persentase Data Set

No	Data	Fitur	Persentase	Jumlah Data	
				Training	Testing
1	1056	1990	10%	951	105
2			20%	845	211
3			50%	528	528
4			80%	212	844
5	3914	4551	10%	3523	391
6			20%	3132	782
7			50%	1957	1957
8			80%	783	3131


- 10% artinya data *testing* diambil 10% dari data set, dan 90% sisanya digunakan sebagai data *training*.

Uji Coba dan Analisa Persentase Data Set

No	Data	Fitur	Persen	MSE	Akurasi (%)		Lama Train (s)
					Train	Test	
1	1056	1990	10%	0,02	0,97	0,47	77
2			20%	0,01	0,98	0,51	52
3			50%	0,02	0,97	0,48	31
4			80%	0,35	0,70	0,32	12
5	3914	4551	10%	0,06	0,94	0,57	2959
6			20%	0,06	0,94	0,58	3279
7			50%	0,04	0,94	0,55	1504
8			80%	0,03	0,92	0,50	871

- Diperlukan data lebih banyak pada data *training* dibandingkan dengan data *testing* untuk mendapat nilai akurasi yang baik.
- Namun, berkas ke-2 dengan 80% mendapat akurasi baik karena 20% data sebagai data *training* dari 3914 sudah mewakili cukup banyak.

Uji Coba dan Analisa Maksimum Epoch



- Semakin besar persentase data *training*, sistem membutuhkan waktu lebih lama untuk *training*.

Uji Coba dan Analisa Variasi Terbaik 1056 Data

No	Variabel	MSE	Akurasi (%)		Lama Train (s)
			Train	Test	
1	Learning Rate : 0,05 Neuron : 1% Persentase : 10%	0,07	0,96	0,50	80
2	Learning Rate : 0,10 Neuron : 1% Persentase : 10%	0,02	0,97	0,47	87
3	Learning Rate : 0,05 Neuron : 1% Persentase : 20%	0,01	0,95	0,54	52
4	Learning Rate : 0,10 Neuron : 1% Persentase : 20%	0,01	0,98	0,52	52

- Variasi ke-3 dan ke-4 memiliki kemiripan. Namun, perbedaan pada akurasi *training* dan *testing*.

Uji Coba dan Analisa Variasi Terbaik 3914 Data

No	Variabel	MSE	Akurasi (%)		Lama Train (s)
			Train	Test	
1	Learning Rate : 0,05 Neuron : 1% Persentase : 10%	0,07	0,94	0,55	3497
2	Learning Rate : 0,10 Neuron : 1% Persentase : 10%	0,06	0,94	0,57	2959
3	Learning Rate : 0,05 Neuron : 1% Persentase : 20%	0,06	0,94	0,58	4461
4	Learning Rate : 0,10 Neuron : 1% Persentase : 20%	0,06	0,94	0,58	3280

- Dengan pertimbangan data sebelumnya, maka variasi terbaik diambil variasi ke-4.

Tabel Kebenaran Klasifikasi 1056 Data

Kelas		Prediksi						Total	Kelas		Prediksi						Total
Target	1	2	3	4	5	6		Target	1	2	3	4	5	6			
	1	<u>138</u>	0	0	0	0	138		1	<u>19</u>	0	3	5	4	1	32	
	2	1	<u>138</u>	0	0	0	139		2	1	<u>25</u>	1	1	0	1	29	
	3	0	0	<u>139</u>	0	0	139		3	3	0	<u>18</u>	2	4	2	29	
	4	0	1	0	<u>131</u>	0	132		4	2	5	4	<u>11</u>	3	6	31	
	5	<u>18</u>	0	0	0	<u>136</u>	154		5	<u>11</u>	3	3	<u>11</u>	<u>19</u>	2	49	
	6	0	0	0	1	0	142	Total	6	4	0	4	<u>11</u>	4	<u>16</u>	39	
Total		157	139	139	132	136	142	845	Total	40	33	33	41	34	28	209	

Data Training

Data Testing

- Pada tahap *training*, 18 data dari kelas *Recreation & Leisure* diprediksi sebagai kelas *Career & Education*.



ITS

Institut
Teknologi
Sepuluh Nopember


Tabel Kebenaran Klasifikasi 3914 Data

Kelas	Prediksi						Total	Kelas	Prediksi						Total	
	1	2	3	4	5	6			1	2	3	4	5	6		
Target	1	<u>149</u>	0	1	0	0	152	Target	1	<u>17</u>	1	7	9	5	0	39
	2	0	<u>131</u>	1	3	0	135		2	2	<u>27</u>	2	5	0	0	36
	3	1	0	<u>636</u>	10	5	0		3	6	2	<u>104</u>	21	12	6	151
	4	<u>106</u>	2	7	<u>1375</u>	17	20		4	<u>33</u>	7	<u>52</u>	<u>254</u>	<u>44</u>	<u>43</u>	433
	5	1	0	0	7	<u>327</u>	3		5	8	1	2	<u>17</u>	<u>29</u>	6	63
	6	0	0	0	5	0	<u>323</u>		6	2	1	6	<u>15</u>	<u>12</u>	<u>24</u>	60
Total		257	133	645	<u>1400</u>	349	348	3132	Total	68	39	173	<u>321</u>	102	79	782

Data Training

Data Testing

- Pada tahap *training*, 106 data dari kelas *Personal Growth* diprediksi sebagai kelas *Career & Education*.
- Jumlah data pada kelas *Personal Growth* yang dominan, menyebabkan kecenderungan prediksi condong ke kelas tersebut.





Kesimpulan

- *Learning rate* mempengaruhi nilai akurasi.
- Neuron pada *hidden layer* yang terlalu sedikit mempengaruhi kecilnya nilai akurasi.
- Maksimum *epoch* tidak mempengaruhi nilai akurasi. Namun, *epoch* yang terlalu sedikit mengurangi nilai akurasi karena sistem memerlukan kesempatan lebih lama untuk mempelajari sistem.
- Untuk sistem *training klasifikasi* perlu dipertimbangkan jumlah data untuk masing-masing kelas, karena adanya dominasi data pada kelas tertentu mempengaruhi hasil klasifikasi. Dan, menyebabkan banyak kesalahan klasifikasi data.