

# Metode Pembelajaran Mesin untuk Memprediksi Emisi Manure Management

Widi Hastomo<sup>1</sup>, Nur Aini<sup>2</sup>, Adhito Satyo Bayangkari Karno<sup>3</sup>, L.M. Rasdi Rere<sup>4</sup>

**Intisari**—Indonesia berkomitmen menurunkan emisi gas rumah kaca (GRK) melalui skema *nationally determined contribution* (NDC). Target yang hendak dicapai untuk menurunkan emisi GRK yaitu 29% melalui skema *business as usual* (BAU) atau 41% dengan bantuan internasional. Target ambisius ini membutuhkan transformasi, baik dalam sistem energi maupun sistem pangan dan tata guna lahan, yang perlu mengatasi potensi pertukaran di antara sejumlah besar target, seperti ketahanan pangan, ketahanan energi, menghindari deforestasi, konservasi keanekaragaman hayati, persaingan penggunaan lahan, serta penggunaan air tawar. Mitigasi dan adaptasi memiliki peran yang saling melengkapi dalam merespons perubahan iklim yang dilakukan pada skala temporal dan spasial. Makalah ini bertujuan untuk melakukan simulasi dan prediksi pada emisi *manure management* penghasil CO<sub>2</sub>eq dengan menggunakan metode pembelajaran mesin *long short-term memory* (LSTM) dan *gated recurrent unit* (GRU). Arsitektur lapisan tersembunyi yang digunakan berjumlah enam kombinasi, sedangkan *dataset* diperoleh dari repositori *fao.org*. *Optimizer* yang digunakan dalam makalah ini yaitu RMSprop, dengan *graphical user interface* menggunakan *dashboard* Streamlit. Hasil dari penelitian ini yaitu; (a) *cattle* dengan lima belas *epoch* menggunakan lapisan tersembunyi empat kombinasi (LSTM, GRU, LSTM, GRU) menghasilkan RMSE 450,601; (b) *non-dairy cattle* dengan lima belas *epoch* dan satu lapisan tersembunyi (GRU, GRU, GRU, GRU) menghasilkan nilai RMSE 361,421; (c) *poultry birds* dengan nilai dua belas *epoch* dan tiga lapisan tersembunyi (GRU, GRU, LSTM, LSTM) menghasilkan nilai RMSE 341,429. Tantangan yang dihadapi adalah penentuan *epoch*, kombinasi lapisan tersembunyi, serta karakteristik *dataset* yang berjumlah relatif sedikit. Hasil dari penelitian ini diharapkan dapat memberikan nilai tambah untuk mengembangkan alat dan model pendukung keputusan yang lebih baik untuk menilai tren emisi di sektor peternakan serta untuk mengembangkan strategi mitigasi emisi CO<sub>2</sub>eq yang mengarah pada praktik pengelolaan pupuk yang berkelanjutan.

**Kata Kunci**—Pembelajaran Mesin, *Manure Management*, GRK, LSTM, GRU.

## I. PENDAHULUAN

Emisi gas rumah kaca (GRK) antropogenik telah meningkat secara signifikan seiring meningkatnya penggunaan bahan bakar fosil, penggundulan hutan, dan perubahan penggunaan lahan. The Intergovernmental Panel on Climate Change (IPCC)

<sup>1,2</sup> Jurusan Manajemen ITB Ahmad Dahlan Jakarta, Jl. Ir H. Juanda No.77, Ciputat Timur, Tangerang Selatan 15419 (telp:021-7430930) e-mail: <sup>1</sup>Widie.has@gmail.com, <sup>2</sup>aini.nur1969@gmail.com

<sup>1,3,4</sup> Magister Teknologi Informasi, STMIK Jakarta STI&K, Jl. BRI Radio Dalam No.17, Kebayoran Baru, Jakarta Selatan 12140 (telp: 021-739 7973; e-mail: <sup>3</sup>adh1t10.2@gmail.com, <sup>4</sup>rasdi@jak-stik.ac.id)

[Diterima: 25 September 2021, Revisi: 29 Desember 2021]

telah menyoroti dampak emisi GRK, khususnya karbon dioksida (CO<sub>2</sub>), dinitrogen oksida (N<sub>2</sub>O), ozon di troposfer (O<sub>3</sub>), metana (CH<sub>4</sub>), dan *chlorofluorocarbons* (CFC) tentang perubahan iklim [1]. Kenaikan rata-rata konsentrasi GRK global lebih tinggi selama setengah abad terakhir dibandingkan tahun-tahun sebelumnya [2]. Kegiatan antropogenik di bidang pertanian dan kehutanan terutama disebabkan oleh intensifikasi dan perubahan penggunaan lahan yang mengakibatkan emisi GRK, sehingga menyebabkan ketidakseimbangan ekosistem [3].

Emisi langsung dari peternakan mengacu pada emisi yang dihasilkan secara langsung dari ternak melalui fermentasi enterik dan kotoran (kotoran dan urine) ekskresi [4]. Secara khusus, CH<sub>4</sub> hasil ternak secara langsung merupakan produk sampingan dari pencernaan melalui fermentasi enterik [4]. CH<sub>4</sub> diproduksi pada herbivor sebagai produk sampingan dari fermentasi enterik, yaitu proses pencernaan yang melibatkan mikroorganisme untuk memecah karbohidrat dan menurunkan menjadi molekul sederhana untuk diserap ke dalam aliran darah. Jumlah CH<sub>4</sub> yang dilepaskan bergantung pada jenis saluran pencernaan, umur, bobot hewan, serta mutu dan kuantitas pakan yang dikonsumsi. Ternak ruminansia (misalnya sapi dan domba) adalah sumber utama CH<sub>4</sub> dengan jumlah produksi sedang. Contoh jenis ternak nonruminansia adalah babi dan kuda [5].

Pengelolaan kotoran hewan (*manure management*) merupakan sumber emisi N<sub>2</sub>O dan CH<sub>4</sub>. N<sub>2</sub>O diproduksi sebagai bagian dari siklus nitrifikasi dan denitrifikasi zat nitrogen organik yang terkandung dalam kotoran hewan. Emisi N<sub>2</sub>O berkaitan dengan penanganan pupuk kandang sebelum kotoran diterapkan ke tanah. CH<sub>4</sub> dari pengelolaan pupuk kandang diproduksi selama penguraian kotoran secara anaerobik dan biasanya jumlahnya lebih kecil daripada emisi fermentasi enterik. Pada prinsipnya, emisi CH<sub>4</sub> terkait dengan fasilitas pengelolaan hewan yang terbatas, yaitu kotoran hewan ditangani dalam bentuk cairan [5].

Sektor peternakan merupakan penghasil emisi GRK terbesar dari sektor pertanian dunia. Fermentasi enterik dan pengelolaan kotoran menyumbang 35-40% dari total emisi CH<sub>4</sub> antropogenik [6]. Emisi CH<sub>4</sub> dari fermentasi enterik dan pengelolaan kotoran mencapai 78,3% dari total emisi CH<sub>4</sub> pertanian [7]. Aktivitas peternakan menyumbang 65% dari total emisi N<sub>2</sub>O antropogenik, yang mewakili 75%-80% dari total emisi pertanian [6]. Emisi N<sub>2</sub>O dari pengelolaan kotoran menyumbang 6,3% dari total emisi N<sub>2</sub>O pertanian [7].

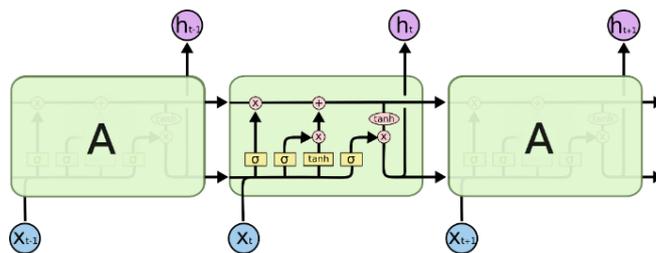
Pemerintah Indonesia berkomitmen untuk menurunkan emisi GRK sebesar 41% dengan bantuan internasional dan 26% dengan usaha sendiri. Hal tersebut sesuai dengan Peraturan Presiden No 61 tahun 2011 tentang penurunan GRK [8]. Pemerintah memberikan edukasi kepada peternak untuk ikut mengurangi gas CH<sub>4</sub> dengan cara substitusi pakan ternak

dengan dedaunan yang rendah emisi gas CH<sub>4</sub>, seperti *Calliandra*, *Gliricidia*, serta *Leucaena*. Makanan ternak yang mengandung tanin dan saponin juga dapat diberikan guna mengurangi gas CH<sub>4</sub> [9].

Dalam beberapa dekade terakhir ini, penggunaan algoritme pembelajaran mesin untuk sebuah model pembuat keputusan prediksi *manure management* telah menarik minat para peneliti. Beberapa penelitian yang telah dilakukan adalah penggunaan algoritme pembelajaran mesin *gradient boosted trees* (GBT), *bagged tree ensembles* (BTE), *random forest ensembles* (RFE), serta *feedforward neural networks* (FNN) untuk memprediksi *liquid dairy manure* [10]; penelitian tentang penggunaan *manure* dari peternakan sapi perah untuk ladang dan tanaman menggunakan algoritme *boosted regression* (BR) [11]; penelitian menggunakan model pembelajaran mesin *multiple linear regression* (MLR), *artificial neural network* (ANN), *gradient boosting machine* (GBM), dan *random forests* (RF) untuk memprediksi CO<sub>2</sub> dan N<sub>2</sub> yang dihasilkan *cattle manure* [12]. Selain itu, telah dilakukan pula penelitian menggunakan metode pembelajaran mesin ANN serta *least squares support vector machine* (LS-SVM) untuk memprediksi pirolisis dari *cattle manure* [13] dan penelitian tentang prediksi emisi pertanian menggunakan algoritme *autoregressive integrated moving average* (ARIMA), *long short-term memory* (LSTM), serta model *simple linear regression* [14].

Sebuah *literature review* telah dilakukan menggunakan metode ANN, *support vector machine* (SVM), *genetic algorithm* (GA), *decision tree* (DT), RF, yang memiliki potensi yang besar untuk berbagai bidang dalam pengambilan keputusan pengelolaan limbah, pengurangan siklus pengolahan limbah, peningkatan pemanfaatan sumber daya, dan mitigasi risiko pencemaran limbah [15]. Penelitian menggunakan pembelajaran mesin *Bayesian network* (BN) serta *boosted regression trees* (BRT) juga telah dilakukan untuk memprediksi nitrogen pada *dairy cattle* [16]. Penelitian terkait mitigasi emisi GRK untuk proyeksi CH<sub>4</sub> menggunakan metode pembelajaran mesin *Gaussian processes*, *ordinary multilinear regression*, serta *neural networks least robust* pada bangunan ternak berventilasi alami pun telah dilakukan [11]. Selain itu, telah dilakukan juga implementasi *deep learning LSTM* untuk memprediksi emisi GRK di bidang pertanian [17]; dan penelitian menggunakan metode ANN untuk memprediksi emisi GRK di bidang pertanian [18]. Metode pembelajaran mesin, *linear regression*, *decision tree regressor*, serta *random forest regressor* juga diusulkan untuk menganalisis dan memprediksi emisi GRK di sektor pertanian [19].

Penelitian pada makalah ini hendak mengambil manfaat dari dua metode pembelajaran mesin LSTM dan *gated recurrent unit* (GRU) untuk memprediksi *manure management* dalam memengaruhi emisi GRK di Indonesia dengan menggunakan enam kombinasi lapisan tersembunyi. Penumpukan lapisan tersembunyi *deep neural networks* (DNN) membuat model lebih dalam dan lebih akurat mendapatkan deskripsi sebagai teknik pembelajaran yang mendalam. Hal ini juga berpotensi memungkinkan keadaan tersembunyi (*hidden state*) di setiap level beroperasi pada skala waktu yang berbeda [20]. Selain itu, hal tersebut juga meningkatkan kedalaman jaringan serta memberikan solusi alternatif yang membutuhkan lebih sedikit



Gbr. 1 Empat lapis fungsi aktivasi pada sel LSTM.

*neuron* dan melakukan pelatihan lebih cepat [21]. Pada akhirnya, penambahan kedalaman ini merupakan jenis optimasi representasional [22].

## II. METODOLOGI

Eksperimen ini menggunakan *dataset manure management* yang diperoleh dari laman repositori *fao.org* [7]. *Dataset* tersebut memiliki atribut nilai dan waktu. Hal ini termasuk dalam kategori data runtun waktu yang dapat digunakan dalam masukan pada metode pembelajaran mesin. Regresi LSTM-GRU dijadikan pilihan untuk memprediksi tren emisi dari *manure management* guna memberikan alternatif solusi untuk mitigasi GRK di Indonesia.

### A. Algoritme Long Short-Term Memory (LSTM)

LSTM adalah jenis *recurrent neural network* (RNN) yang memungkinkan jaringan mempertahankan ketergantungan jangka panjang antara data pada waktu tertentu dari banyak langkah waktu sebelumnya [23]. LSTM memiliki bentuk rantai modul berulang dari jaringan saraf tiruan, dengan setiap modul mencakup tiga gerbang kontrol, yaitu gerbang *forget* (*forget gate*), gerbang masukan (*input gate*), dan gerbang keluaran (*output gate*). Setiap gerbang terdiri atas lapisan jaring saraf *sigmoid* dan operasi perkalian *pointwise*. Hasil dari keluaran pada lapisan *sigmoid* merupakan angka dalam interval [0, 1], mewakili sebagian informasi masukan yang harus dilewati. Sebagai penggunaan RNN untuk data runtun waktu, LSTM membaca urutan vektor masukan  $x = \{x_1, x_2, \dots, x_t, \dots\}$ , dengan  $x_t \in R^m$  mewakili vektor  $m$ -dimensi pembacaan untuk  $m$  variabel pada contoh waktu  $t$ . Gbr. 1 merupakan empat lapis fungsi aktivasi pada LSTM.

Mengingat informasi baru  $x_t$  dalam keadaan  $t$ , modul LSTM bekerja sebagai berikut. Pertama, modul LSTM menentukan informasi lama yang harus dilupakan dengan mengeluarkannya dalam angka [0, 1].

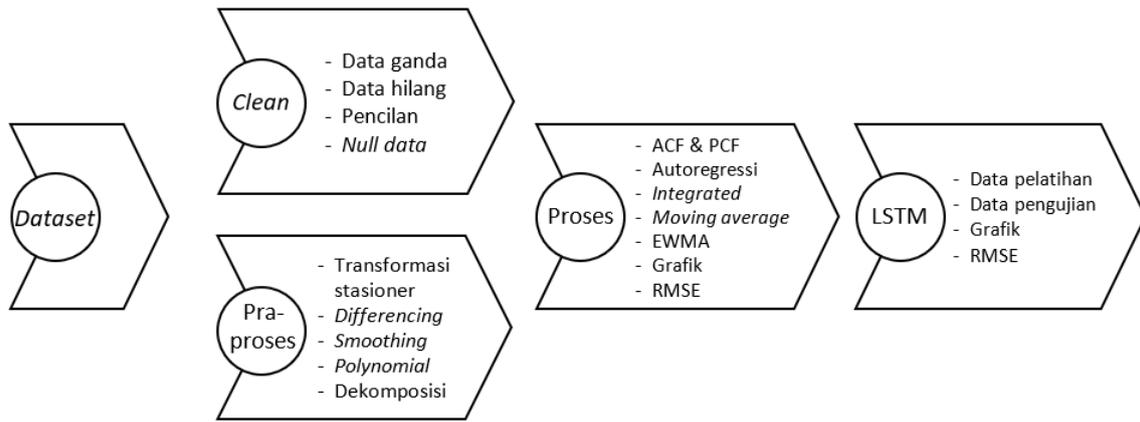
$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

dengan  $h_{t-1}$  adalah keluaran dalam keadaan  $t-1$ ,  $W_f$  adalah matriks bobot, dan  $b_f$  adalah *bias* dari gerbang *forget*. Kemudian,  $x_t$  diproses sebelum disimpan dalam *cell state*. Nilai  $i_t$  ditentukan di gerbang masukan bersama dengan nilai kandidat vektor  $C_t$  yang dihasilkan oleh lapisan *tanh* pada saat yang sama untuk diperbarui dalam *cell state* baru  $C_t$ , dengan

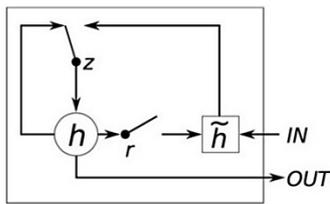
$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$



Gbr. 2 Alur eksperimen.



Gbr. 3 Ilustrasi grafis GRU.

dengan  $(W_i, b_i)$  dan  $(W_c, b_c)$  masing-masing adalah matriks bobot dan *bias* gerbang masukan dan memori *cell state*. Akhirnya, gerbang keluaran didefinisikan oleh (5), dengan  $W_o$  dan  $b_o$  adalah bobot matriks dan *bias* gerbang keluaran, yang menentukan bagian dari keluaran *cell state*.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = O_t + \tanh(C_t). \tag{6}$$

Gerbang keluaran mengontrol banyaknya aktivasi setiap unit yang dapat dipertahankan. Hal ini memungkinkan sel LSTM menyimpan informasi yang tidak relevan dengan keluaran saat ini, tetapi mungkin relevan di masa mendatang. Kemampuan LSTM untuk mengontrol cara informasi disimpan di setiap unit telah terbukti bermanfaat secara umum.

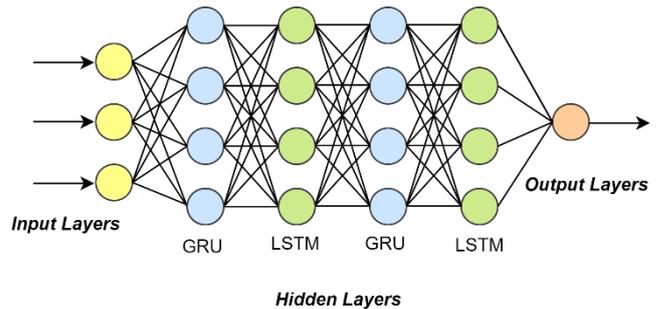
Langkah awal dari eksperimen ini dimulai dengan masukan *dataset*. Tahapan selanjutnya adalah *cleansing* data, yang berfungsi untuk membersihkan data dari data ganda, hilang, penculan/*outlier* serta *null*, dilanjutkan dengan pra-proses, yaitu proses transformasi stasioner, *differencing*, *smoothing*, polinomial, dan dekomposisi. Lalu, tahap selanjutnya adalah proses autoregresi, *moving average*, grafik, serta RMSE. Proses selanjutnya yaitu analisis data, yang terdiri atas pelatihan data dan pengujian data. Hasilnya berupa visualisasi grafik serta nilai RMSE. Alur eksperimen ditunjukkan pada Gbr. 2.

**B. Algoritme Gated Recurrent Unit (GRU)**

GRU pertama kali diusulkan pada tahun 2014 [24]. GRU mirip dengan LSTM, tetapi lebih sederhana untuk dihitung dan diimplementasikan. Struktur sel GRU ditunjukkan pada Gbr. 3. Secara umum, sel GRU terdiri atas dua gerbang, yaitu gerbang reset, *r*, dan gerbang pembaruan, *z*. Mirip dengan sel LSTM, keluaran keadaan tersembunyi di waktu *t* dihitung menggunakan keadaan tersembunyi waktu *t-1* dan

TABEL I  
DESAIN LAPISAN TERSEMBUNYI UNTUK ENAM MODEL

Lapisan Tersembunyi	1	2	3	4
Model 0	LSTM	LSTM	LSTM	LSTM
Model 1	GRU	GRU	GRU	GRU
Model 2	LSTM	LSTM	GRU	GRU
Model 3	GRU	GRU	LSTM	LSTM
Model 4	LSTM	GRU	LSTM	GRU
Model 5	GRU	LSTM	GRU	LSTM



Gbr. 4 Desain lapisan tersembunyi (model 5).

memasukkan nilai runtun waktu pada waktu *t*, seperti disajikan pada (7). Fungsi gerbang reset mirip dengan gerbang *forget* LSTM karena GRU memiliki beberapa kesamaan dengan LSTM.

$$h_t = f(h_{t-1}, x_i). \tag{7}$$

**C. Kombinasi Lapisan Tersembunyi LSTM dan GRU**

Terdapat tiga lapisan di dalam pembelajaran mesin, yaitu lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Dalam makalah ini, dipergunakan empat lapisan tersembunyi, dengan menggunakan kombinasi LSTM dan GRU untuk setiap lapisan [25], [26]. Desain lapisan ini membentuk enam model untuk setiap *dataset*, seperti terlihat pada Tabel I.

Keberhasilan DNN umumnya dikaitkan dengan hierarki yang diperkenalkan karena beberapa lapisan. Setiap lapisan memproses beberapa bagian dari tugas yang hendak diselesaikan dan meneruskannya ke bagian berikutnya. Dalam pengertian ini, DNN dapat dilihat sebagai pemrosesan *pipeline*, yaitu setiap lapisan menyelesaikan bagian dari tugas sebelum

## INDONESIA

```
df_v1=df.loc[df['Area']=='Indonesia'][['Item','Element','Year','Unit','Value']]
df_v1
```

	Item	Element	Year	Unit	Value
1095162	Buffaloes	Stocks	1961	Head	2.893281e+06
1095163	Buffaloes	Stocks	1962	Head	2.803000e+06
1095164	Buffaloes	Stocks	1963	Head	2.836000e+06
1095165	Buffaloes	Stocks	1964	Head	2.836000e+06
1095166	Buffaloes	Stocks	1965	Head	2.951000e+06
...	...	...	...	...	...
1107637	Swine Emissions (CO2eq) (Manure management)		2016	gigagrams	1.226370e+03
1107638	Swine Emissions (CO2eq) (Manure management)		2017	gigagrams	1.262807e+03
1107639	Swine Emissions (CO2eq) (Manure management)		2018	gigagrams	1.325453e+03
1107640	Swine Emissions (CO2eq) (Manure management)		2030	gigagrams	1.188199e+03
1107641	Swine Emissions (CO2eq) (Manure management)		2050	gigagrams	1.276329e+03

12480 rows × 5 columns

Gbr. 5 Data mentah *manure mangement* (sumber: *fao.org*).

meneruskannya ke bagian berikutnya, sampai akhirnya lapisan terakhir memberikan keluaran [27]. Gbr. 4 merupakan ilustrasi kombinasi lapisan tersembunyi untuk model 5.

#### D. Root Mean Squared Error (RMSE) dan Mean Square Error (MSE)

RMSE merupakan akar kuadrat dari nilai yang diperoleh dari fungsi *mean square error* (MSE). Dengan menggunakan RMSE, dapat dengan mudah di-plot perbedaan antara nilai estimasi dan nilai aktual dari suatu parameter model. Rumus dari RMSE dan MSE ditunjukkan pada (8) dan (9).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_1 - \hat{y}_1)^2}{n}} \quad (8)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_1 - \hat{y}_1)^2 \quad (9)$$

dengan

$$\begin{aligned} \hat{y}_1, \hat{y}_2, \dots, \hat{y}_n &= \text{nilai yang diprediksi} \\ y_1, y_2, \dots, y_n &= \text{nilai yang diamati} \\ n &= \text{jumlah data yang diamati.} \end{aligned}$$

#### E. RMSProp Optimizer

Pengoptimal *root mean squared propagation* (RMSProp) mirip dengan algoritme penurunan gradien dengan momentum. RMSProp membatasi osilasi pada arah vertikal. Hal ini dapat meningkatkan kecepatan belajar dan algoritme, serta dapat mengambil langkah yang lebih besar dalam arah horizontal yang konvergen lebih cepat. Perbedaan antara RMSprop dan *gradient descent* terletak pada cara gradien dihitung.

Penentuan parameter dibutuhkan untuk proses kompilasi serta menangani dan melatih jaringan. RMSprop digunakan untuk melatih fungsi *loss* dan jaringan dalam mengevaluasi *jaringan* yang diminimalkan oleh algoritme tersebut. Langkah selanjutnya menentukan metrik yang akan dikumpulkan sambil menyesuaikan model di samping fungsi *loss*.

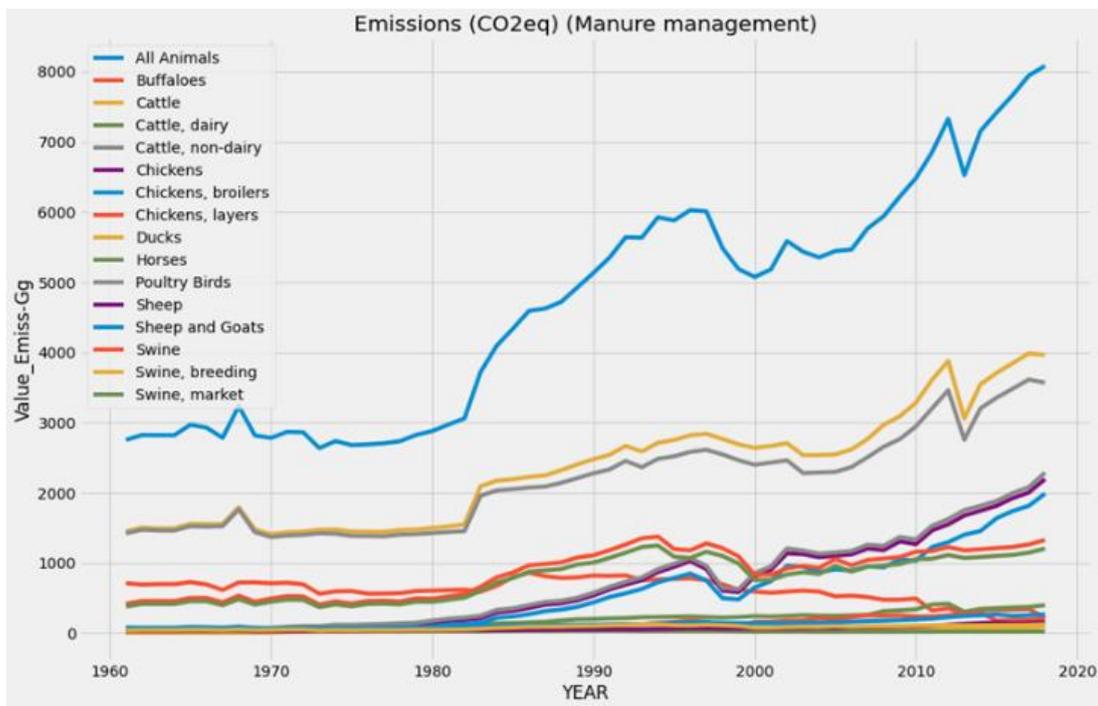
#### F. Streamlit

Pada makalah ini digunakan *graphical user interface* (GUI) Streamlit. Streamlit adalah kerangka kerja web yang ditujukan untuk menyebarkan model dan visualisasi dengan mudah menggunakan bahasa Python, yang cepat dan minimalis tetapi juga memiliki tampilan yang cukup baik serta ramah pengguna. Tersedia *widjet* bawaan untuk masukan pengguna, seperti pengunggahan gambar, penggeser, masukan teks, dan elemen *hypertext markup language* (HTML) lain yang sudah dikenal, seperti *checkboxes* dan *radio buttons*. Setiap kali pengguna berinteraksi dengan aplikasi Streamlit, skrip Python dijalankan kembali dari atas ke bawah. Hal ini merupakan sebuah konsep penting yang perlu diingat saat mempertimbangkan berbagai status aplikasi yang akan dipilih.

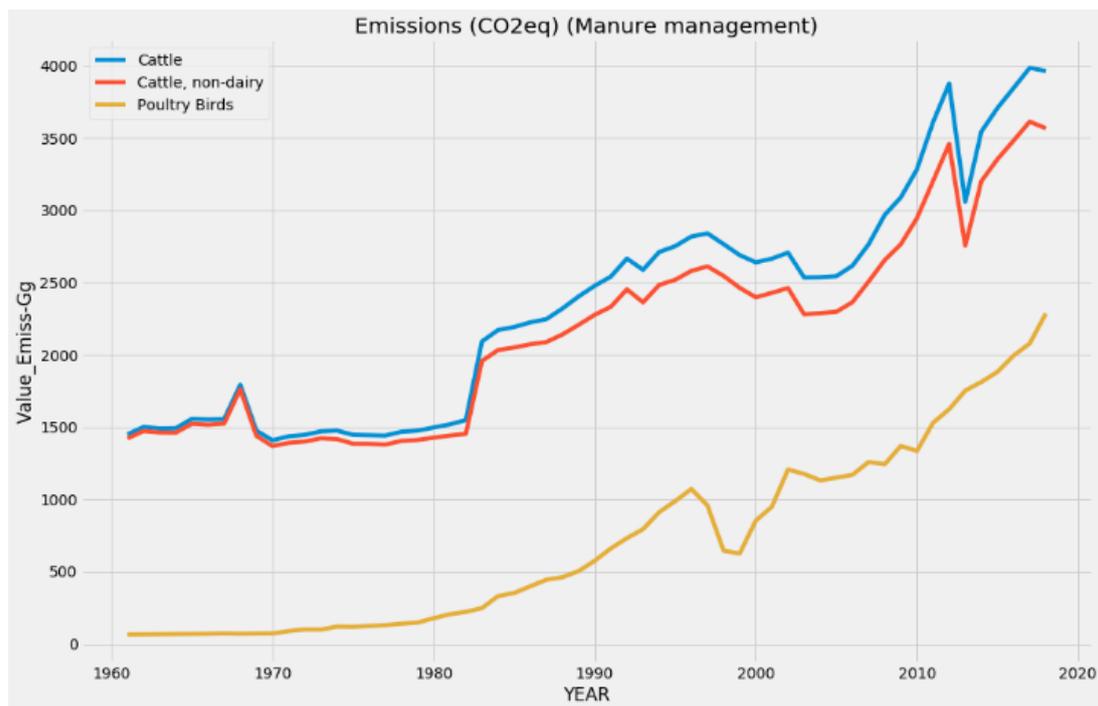
Streamlit merupakan aplikasi yang tidak berbayar dan pengguna tidak perlu memiliki pengetahuan pengembangan *front-end* yang mahir untuk mengoperasikannya. Streamlit dapat dijalankan pada editor Anaconda serta bahasa Python seri 3.7 ke atas, tetapi tidak mendukung pada editor Jupyter Notebook, sehingga harus dikonversi ke editor Pycharm atau Visual Code. Tampilan beranda pada aplikasi Streamlit dapat dipisahkan menjadi dua bagian, yaitu *buttons*, untuk pemilihan menu, serta tampilan *visual chart*. Hal ini menyebabkan dibutuhkan *library* NumPy serta Pandas untuk menampilkan grafik. Keluaran grafik sejalan dengan hasil olah data metode pembelajaran mesin menggunakan kombinasi lapisan tersembunyi LSTM dan GRU. *Buttons* berfungsi untuk memilih *dataset* dari kategori negara, jenis hewan, arsitektur lapisan tersembunyi, *optimizer*, serta pilihan untuk *epoch* dan prediksi dalam beberapa tahun ke depan.

### III. HASIL DAN PEMBAHASAN

Mesin mampu belajar dari data runtun waktu. Oleh karena itu, dari *dataset* yang ada, diambil *dataset* pelatihan sejumlah 70% hingga 80% dari keseluruhan *dataset*. Selanjutnya, dari



Gbr. 6 Emisi CO<sub>2</sub>eq di Indonesia berdasarkan hewan.



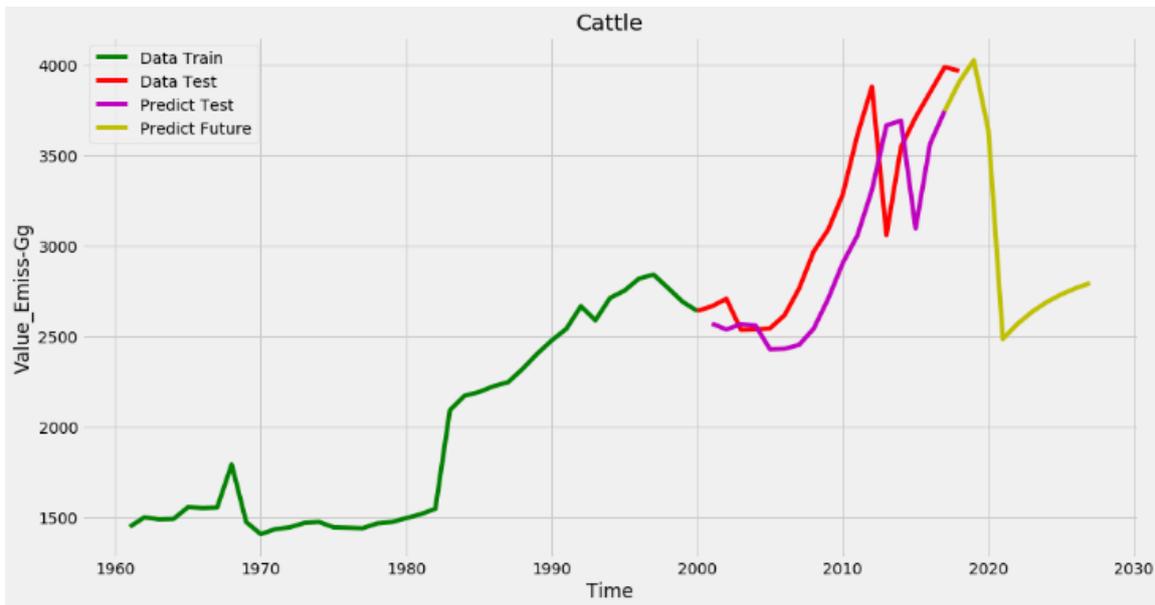
Gbr. 7 Emisi CO<sub>2</sub>eq di Indonesia berdasarkan penghasil emisi tinggi.

hasil pembelajaran, mesin di uji untuk memprediksi *dataset* pengujian (20% hingga 30%). Hasil prediksi *dataset* pengujian diukur nilai kesalahannya dengan nilai *real testing dataset* (data target). Nilai kesalahan yang diperoleh digunakan untuk memperbaiki (*update*) nilai bobot. Nilai bobot yang baru dipergunakan dalam prediksi iterasi selanjutnya.

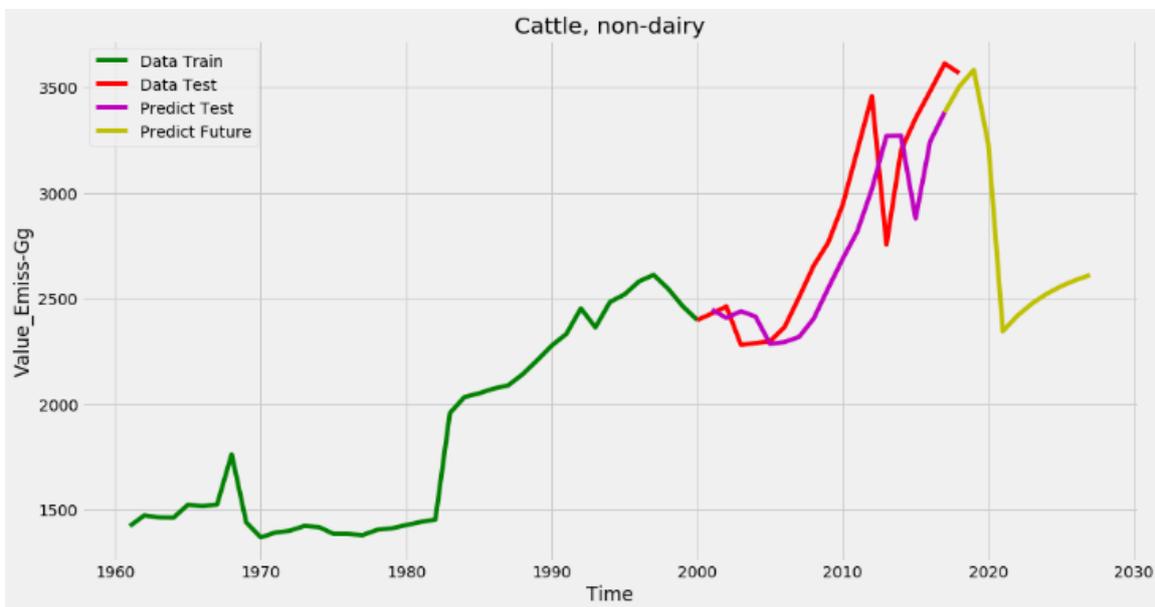
Data mentah *manure management* ini diperoleh dari *fao.org*. Food and Agriculture Organization (FAO) bekerja dengan

negara-negara lain untuk mengatasi kelaparan, kemiskinan, dan untuk mengurangi efek perubahan iklim. Data yang diambil merupakan data tahunan, mulai dari tahun 1961 hingga tahun 2021, yang berisi 12.480 baris. Proses dan hasil ekstraksi data dari *fao.org* diperlihatkan pada Gbr. 5. Data mentah ini terdiri atas lima fitur kolom, yaitu *item*, *element*, *year*, *unit*, dan *value*.

Gbr. 6 merupakan grafik dari emisi CO<sub>2</sub>eq dari tahun 1961 hingga tahun 2018 untuk semua hewan ternak. Dari lima belas



Gbr. 8 Grafik prediksi *cattle*.



Gbr. 9 Grafik prediksi *non-dairy cattle*.

hewan ternak tersebut, dipilih data emisi yang paling tinggi, yaitu *cattle*, *non-dairy cattle*, dan *poultry birds*. Faktor lain yang digunakan dalam menentukan tiga objek ini yaitu rujukan dari penelitian yang telah dilakukan, yang mengambil sampel dari 25 peternakan sapi di Belanda dalam kurun waktu 2006-2018 [16]. Penelitian lain mengambil objek di peternakan di Jerman Utara [28].

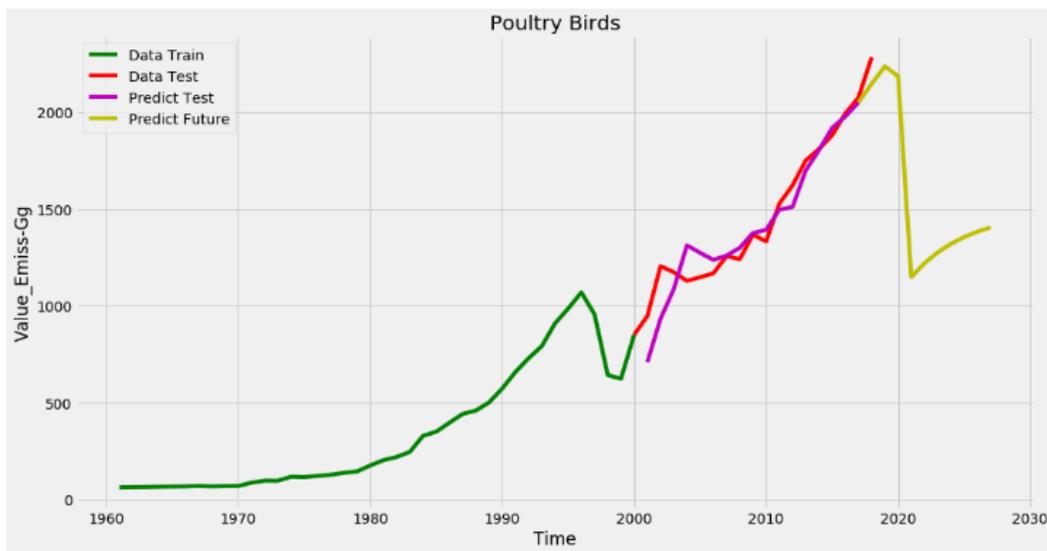
Gbr. 7 memperlihatkan tren peningkatan emisi CO<sub>2</sub>eq dari tiga hewan ternak yang paling dominan, yaitu *cattle*, *non-dairy cattle*, dan *poultry birds*. Indonesia telah melakukan banyak upaya untuk memenuhi *sustainable development goals* (SDGs) dan tujuan Perjanjian Paris. Sejumlah kebijakan dan tindakan inovatif telah dikeluarkan untuk mengubah sistem pangan dan tata guna lahan untuk mengurangi emisi GRK, melestarikan dan memulihkan keanekaragaman hayati, mempromosikan

TABEL II  
OPTIMASI KOMBINASI LAPISAN TERSEMBUNYI *CATTLE*

Kombinasi Lapisan Tersembunyi	Epoch	RMSE
LSTM, GRU, LSTM, GRU	5	956,065
	<b>10</b>	<b>425,170</b>
	15	436,719
	20	586,875

pola makan yang sehat, beradaptasi dengan perubahan iklim, dan memenuhi kendala lingkungan lainnya [29].

Peningkatan GRK berdampak pada peningkatan rata-rata temperatur bumi. Hal ini dapat mengakibatkan perubahan iklim, memicu bencana dengan frekuensi lebih sering dan lebih besar, serta dapat mengancam keberlanjutan ekosistem global [30]. IPCC telah menyatakan bahwa pemanasan global akan



Gbr. 10 Grafik prediksi *poultry birds*.

TABEL III  
OPTIMASI KOMBINASI LAPISAN TERSEMBUNYI *NON-DAIRY CATTLE*

Kombinasi Lapisan Tersembunyi	Epoch	RMSE
GRU, GRU, GRU, GRU	5	550,549
	10	369,885
	<b>15</b>	<b>360,848</b>
	20	367,339

TABEL IV  
OPTIMASI KOMBINASI LAPISAN TERSEMBUNYI *POULTRY BIRDS*

Kombinasi Lapisan Tersembunyi	Epoch	RMSE
GRU, GRU, LSTM, LSTM	5	969,337
	10	345,169
	<b>15</b>	<b>325,145</b>
	20	375,852

berdampak pada berbagai aspek ekonomi dan pembangunan, terutama di negara-negara berkembang, termasuk Indonesia. Sebagai negara kepulauan terbesar dengan dataran rendah dan pulau-pulau kecil yang luas, Indonesia merupakan salah satu negara yang paling rentan terhadap dampak negatif perubahan iklim. Indonesia menghadapi risiko kehilangan pulau-pulau kecil dan penyempitan wilayah pesisir akibat naiknya permukaan air laut yang akan mengancam kota-kota yang berada di garis pantai [29].

Hasil optimasi kombinasi lapisan tersembunyi *manure management* dari kategori *cattle* adalah sebagai berikut. Terlihat pada Gbr. 8 dan Tabel II bahwa dengan sepuluh *epoch* menggunakan empat lapisan dari kombinasi (LSTM, GRU, LSTM, GRU), dihasilkan RMSE sebesar 425,170. Karakteristik *epoch* menjadi tantangan tersendiri pada metode pembelajaran mesin yang diuji coba dengan data yang relatif sedikit [31]. Dari grafik prediksi masa depan, terlihat tren penurunan, dimulai dari tahun 2019 hingga mencapai titik terendah pada tahun 2021. Tahun 2021 merupakan tahun kedua di masa pandemi. Pada semester satu, ekonomi Indonesia mengalami tren positif [32]. Terlihat pada grafik emisi CO<sub>2</sub>eq, terjadi kenaikan (grafik prediksi) diikuti dengan kondisi ekonomi yang membaik (kebutuhan nutrisi hewani masyarakat meningkat) [33].

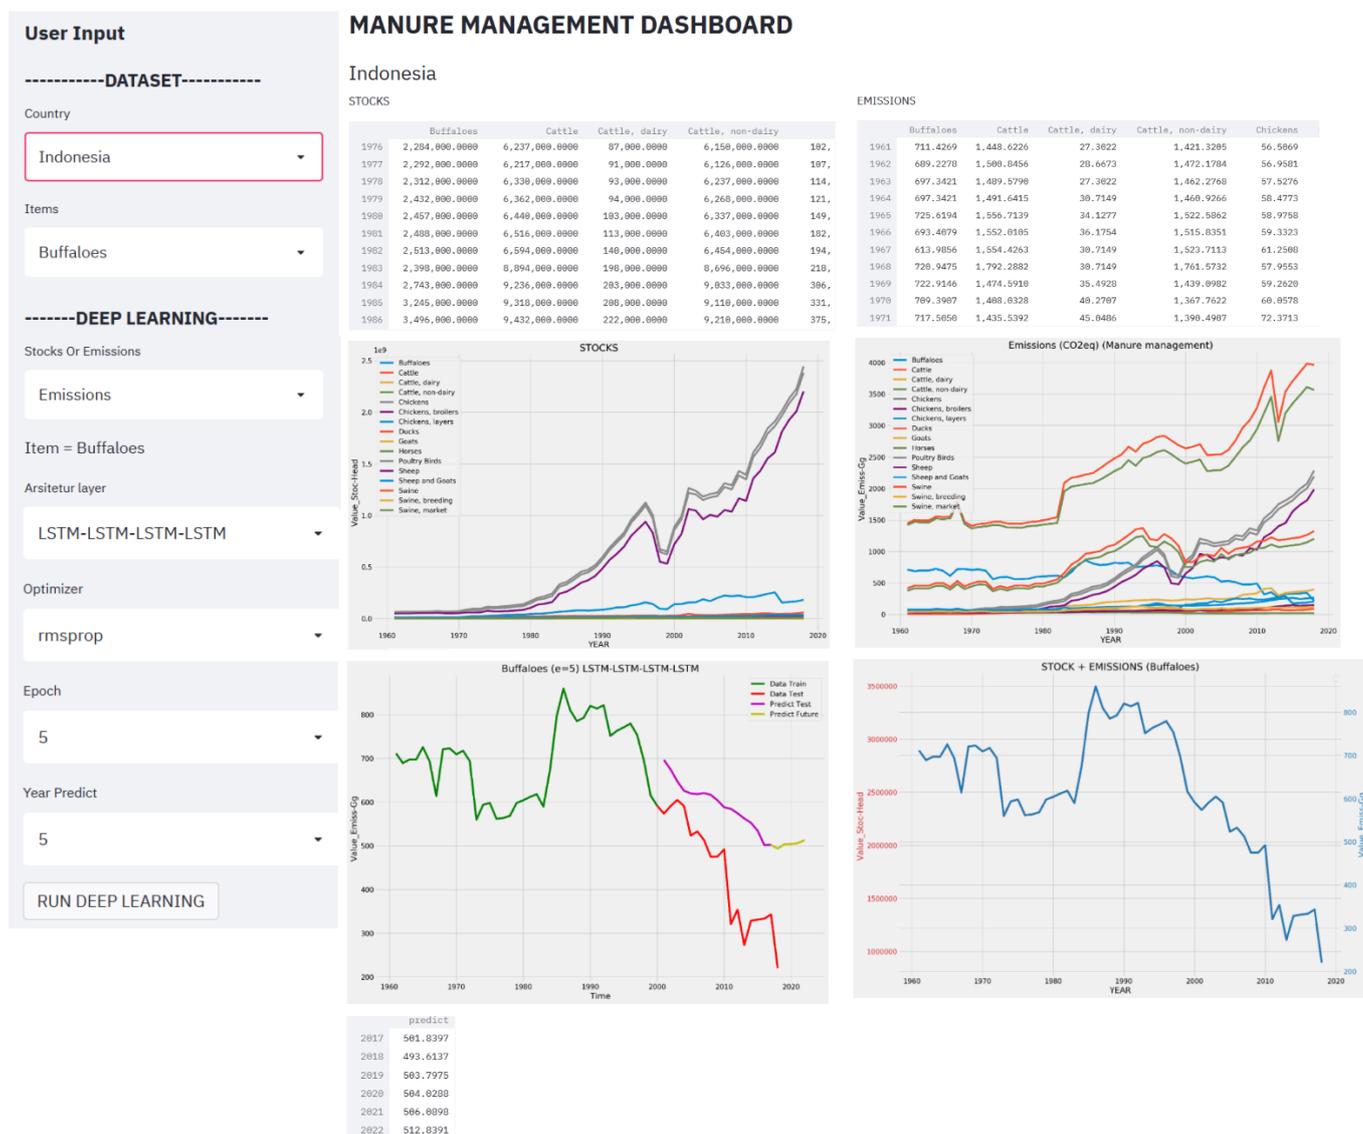
Hasil optimasi kombinasi lapisan tersembunyi *manure management* dari kategori *non-dairy cattle* pada lima belas *epoch* satu lapisan (GRU, GRU, GRU, GRU) dengan nilai RMSE 360,848 ditunjukkan pada Gbr. 9 dan Tabel III. Prediksi pada tahun 2020 menunjukkan adanya penurunan emisi CO<sub>2</sub>eq hingga mencapai 50%. Hal ini dimungkinkan terjadi karena adanya pandemi yang terjadi sejak awal Maret 2020. Salah satu faktor turunnya daya beli masyarakat di saat pandemi diakibatkan oleh melonjaknya harga daging sapi serta naiknya nilai tukar rupiah, yang mencapai Rp17.000 [34].

Hasil optimasi kombinasi lapisan tersembunyi *manure management* dari kategori *poultry birds* diperlihatkan pada Gbr. 10 dan Tabel IV, dengan lima belas *epoch*, tiga lapisan (GRU, GRU, LSTM, LSTM), dengan nilai RMSE 325,145. Salah satu kategori dari *poultry birds* adalah ayam pedaging. Di awal pandemi, harga ayam pedaging turun drastis, jauh di bawah harga pokok penjualan (HPP). Faktor penyebabnya adalah *panic selling* serta pembatasan sosial berskala besar (PSBB) [35]. Berkurangnya konsumsi masyarakat secara drastis ini berdampak pada penurunan emisi CO<sub>2</sub>eq dari sektor *poultry birds*.

Gbr. 11 merupakan *dashboard artificial intelligent manure management*. *User interface* ini memudahkan pengguna untuk melihat simulasi dan prediksi emisi GRK di Indonesia. Pemanggilan *dashboard* Streamlit ini dilakukan menggunakan Anaconda Prompt yang diuji coba pada komputasi *localhost*.

#### IV. KESIMPULAN

Hasil eksperimen menunjukkan bahwa secara umum metode pembelajaran mesin menggunakan kombinasi lapisan tersembunyi dapat melakukan simulasi dan prediksi di masa depan untuk opsi mitigasi GRK pada *manure management*. Dari total lima belas hewan ternak yang mengeluarkan emisi GRK, dipilih tiga hewan ternak yang mengeluarkan emisi yang paling tinggi dari tahun 1961 hingga tahun 2021, yaitu *cattle*, *non-dairy cattle*, dan *poultry birds*. Penurunan emisi CO<sub>2</sub>eq secara signifikan pada tahun 2020 terjadi karena berkurangnya konsumsi masyarakat akibat terhambatnya rantai pasokan dengan adanya PSBB (kebijakan pandemi COVID-19).



Gbr. 11 User interface Streamlit.

Eksperimen ini diharapkan dapat memberikan nilai tambah untuk mengembangkan alat dan model pendukung keputusan yang lebih baik untuk menilai tren emisi di sektor peternakan. Makalah ini juga diharapkan dapat menginformasikan pengetahuan untuk mengembangkan strategi mitigasi emisi CO<sub>2</sub>eq selama penyimpanan pupuk kandang, yang mengarah pada praktik pengelolaan pupuk yang berkelanjutan. Tantangan dalam mengolah data dengan metode pembelajaran mesin adalah data berjumlah relatif banyak, sedangkan data sekunder ini hanya sejumlah 58 baris untuk setiap hewan ternak. Karakteristik dengan jumlah data yang terbatas linier dengan belum optimalnya hasil RMSE. Penggunaan *dataset* primer dari beberapa peternakan dapat menjadi pilihan untuk menambah masukan pada metode pembelajaran mesin.

Pengembangan metode pembelajaran mesin serta *optimizer* yang lainnya perlu diuji coba pada penelitian selanjutnya agar didapatkan hasil yang optimal. Pengolahan *dataset* dari negara lain yang memiliki tingkat klasifikasi *gross national income* (GNI) yang setara perlu dilakukan untuk membandingkan tren

emisi CO<sub>2</sub>eq untuk menentukan langkah mitigasi di masa depan.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan.

KONTRIBUSI PENULIS

Konseptualisasi, Widi Hastomo dan Nur Aini; metodologi, Widi Hastomo dan Adhitio Satyo Bayangkari Karno; perangkat lunak, Widi Hastomo dan Adhitio Satyo Bayangkari Karno; analisis formal, Widi Hastomo dan L.M. Rasdi Rere; investigasi, Widi Hastomo dan Adhitio Satyo Bayangkari Karno; validasi, L.M. Rasdi Rere dan Nur Aini; kurasi data, Widi Hastomo dan Adhitio Satyo Bayangkari Karno; penulisan-penyusunan draf asli, Widi Hastomo, Nur Aini, Adhitio Satyo Bayangkari Karno dan L.M. Rasdi Rere; penulisan-peninjauan dan penyuntingan, Widi Hastomo, Adhitio Satyo Bayangkari Karno, Nur Aini dan L.M. Rasdi

Rere; visualisasi, Widi Hastomo dan Adhitio Satyo Bayangkari Karno; pengawasan, L.M. Rasdi Rere; administrasi proyek, Nur Aini; akuisisi pendanaan, Widi Hastomo dan Nur Aini.

#### UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan kepada PP Muhammadiyah yang telah mendukung penelitian ini pada program Hibah RisetMU *Bacth 5* dengan ID 2826.

#### REFERENSI

- [1] R.K. Pachauri, dkk., Eds., *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report*, Jenewa, Swiss: Intergovernmental Panel on Climate Change, 2015.
- [2] M. Allen, dkk., "Summary for Policymakers," dalam *Global Warming of 1.5°C. An IPCC Special Report on the Impacts of Global Warming of 1.5°C above Pre-industrial Levels and Related Global Greenhouse Gas Mission Pathways, in the Context of Strengthening the Global Response to the Threat of Climate Change, Sustainable Development, and Efforts to Eradicate Poverty*, V. Masson-Delmotte, dkk., Eds., Jenewa, Swiss: Intergovernmental Panel on Climate Change, 2015.
- [3] V.P. Aneja, W.H. Schlesinger, dan J.W. Erisman, "Effects of Agriculture upon the Air Quality and Climate: Research, Policy, and Regulations," *Environ. Sci. Technol.*, Vol. 43, No. 12, hal. 4234–4240, 2009.
- [4] T. Jungbluth, E. Hartung, dan G. Brose, "Greenhouse Gas Emissions from Animal Houses and Manure Stores," *Nutr. Cycl. Agroecosystems*, Vol. 60, No. 1, hal. 133–145, 2001.
- [5] O. Gavriloza, dkk., "Emissions from Livestock and Manure Management," dalam *2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories*, Vol. 4, E.C. Buendia, Eds., Jenewa, Swiss: Intergovernmental Panel on Climate Change, 2019.
- [6] V. Sejian, J. Gaughan, L. Baumgard, dan C. Prasad, Eds., *Climate Change Impact on Livestock: Adaptation and Mitigation*. New Delhi, India: Springer, 2015.
- [7] (2020) "FAOSTAT Agriculture Total Online Database," [Online], <http://www.fao.org/faostat/en/#data/GT>, tanggal akses: 20-Okt-2021.
- [8] "Rencana Aksi Nasional Penurunan Emisi Gas Rumah Kaca Peraturan Presiden," Peraturan Presiden Republik Indonesia, No. 61, 2011.
- [9] (2017) "Mengurangi Emisi Gas Rumah Kaca (GRK) Melalui Pakan Ternak," [Online], <http://ditjenppi.menlhk.go.id/kcpi/index.php/aksi/mitigasi/implementasi/303-mengurangi-emisi-gas-rumah-kaca-grk-melalui-pakan-ternak>, tanggal akses: 20-Okt-2021.
- [10] R.A. Genedy dan J.A. Ogejo, "Using Machine Learning Techniques to Predict Liquid Dairy Manure Temperature During Storage," *Comput. Electron. Agric.*, Vol. 187, hal. 1-10, 2021.
- [11] H. Mollenhorst, M.H.A. de Haan, J. Oenema, dan C. Kamphuis, "Field and Crop Specific Manure Application on a Dairy Farm Based on Historical Data and Machine Learning," *Comput. Electron. Agric.*, Vol. 175, hal. 1-8, 2020.
- [12] J. Zhang, dkk., "TG-FTIR and Py-GC/MS Analyses of Pyrolysis Behaviors and Products of Cattle Manure in CO<sub>2</sub> and N<sub>2</sub> Atmospheres: Kinetic, Thermodynamic, and Machine-Learning Models," *Energy Convers. Manag.*, Vol. 195, hal. 346–359, 2019.
- [13] H. Cao, Y. Xin, dan Q. Yuan, "Prediction of Biochar Yield from Cattle Manure Pyrolysis via Least Squares Support Vector Machine Intelligent Approach," *Bioresour. Technol.*, Vol. 202, hal. 158–164, 2016.
- [14] M. Homaira dan R. Hassan, "Prediction of Agricultural Emissions in Malaysia Using Machine Learning Algorithms," *Int. J. Perceptive, Cogn. Comput.*, Vol. 7, No. 1, hal. 33–40, 2021.
- [15] H.-N. Guo, dkk., "Application of Machine Learning Methods for the Prediction of Organic Solid Waste Treatment and Recycling Processes: A Review," *Bioresour. Technol.*, Vol. 319, hal. 1-13, 2021.
- [16] H. Mollenhorst, dkk., "Predicting Nitrogen Excretion of Dairy Cattle with Machine Learning," dalam *Environmental Software Systems. Data Science in Action. ISESS 2020. IFIP Advances in Information and Communication Technology*, Vol 554, I.N. Athanasiadis, S.P. Frysinger, G. SchimakWillem, dan J. Knibbe, Eds., Cham, Swiss: Springer, 2020, hal. 132-138.
- [17] L. Uwamahoro dan P. Niyigena, "Deep Learning in Greenhouse Gases Emissions from Agriculture Activities in Rwanda Using Long Short Term Memory Recurrent Neural Network," *Int. Res. J. Eng. Technol.*, Vol. 6, No. 10, hal. 928–931, 2019.
- [18] K. Kononenko dan D. Demidov, "Use of Artificial Neural Networks to Predict Greenhouse Gases Emissions," *Int. Scientific Conf. Eng. Rural Dev.*, 2020, hal. 892–896.
- [19] P.K. KosamkarEmail dan V.Y. Kulkarni, "Effect of Soil and Climatic Attribute on Greenhouse Gas Emission from Agriculture Sector," dalam *Evolution in Computational Intelligence. Advances in Intelligent Systems and Computing*, Vol. 1176, V. Bhateja, S.-L. Peng, S.C. Satapathy, dan Y.-D. Zhang, Eds., Singapura, Singapura: Springer, 2021, hal. 91-101.
- [20] M. Hermans dan B. Schrauwen, "Training and Analyzing Deep Recurrent Neural Networks," dalam *Advances in Neural Information Processing Systems 26 (NIPS 2013)*, C.J.C. Burges, dkk., Eds., Red Hook, AS: Curran Associates Inc., 2013, hal. 192–196.
- [21] L.M.R. Rere, M.I. Fanany, dan A.M. Arymurthy, "Simulated Annealing Algorithm for Deep Learning," *Procedia Comput. Sci.*, Vol. 72, hal. 137–144, 2015.
- [22] R. Pascanu, C. Gulcehre, K. Cho, dan Y. Bengio, "How to Construct Deep Recurrent Neural Networks," *2nd Int. Conf. Learn. Represent. (ICLR 2014)*, 2014, hal. 1–13.
- [23] S. Hochreiter dan J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, Vol. 9, No. 8, hal. 1735–1780, 1997.
- [24] C. Gulcehre, K. Cho, R. Pascanu, dan Y. Bengio, "Learned-norm Pooling for Deep Neural Networks," 2014, *arXiv:1311.1780*.
- [25] A.S.B. Karno, W. Hastomo, dan Sutarno, "Optimalisasi Data Terbatas Prediksi Jangka Panjang COVID-19 dengan Kombinasi LSTM dan GRU," *Pros. Sem. SeNTIK*, Vol. 4, No. 1, hal. 181–191, 2020.
- [26] W. Hastomo, dkk., "Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19," *J. Eduk., Penelit. Inform. (JEPIN)*, Vol. 7, No. 2, hal. 133–140, 2021.
- [27] J. Chung, C. Gulcehre, K. Cho, dan Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," 2014. *arXiv:1412.3555*.
- [28] S. Hempel, dkk., "Supervised Machine Learning to Assess Methane Emissions of a Dairy Building with Natural Ventilation," *Appl. Sci.*, Vol. 10, No. 19, hal. 1–21, 2020.
- [29] (2021) "Long-term Strategy on Low Carbon and Climate Resilience 2050 (LTS-LCCR 2050)," [Online], <https://www.appi.or.id/public/images/img/27e6305e-54ce-4369-9a67-3f31d21338e7.pdf>, tanggal akses: 20-Okt-2021.
- [30] H. Shaftel (2021) "Overview: Weather, Global Warming and Climate Change," [Online], <https://climate.nasa.gov/resources/global-warming-vs-climate-change/>, tanggal akses: 20-Okt-2021.
- [31] W. Hastomo, dkk., "Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia," *J. Phys. Conf. Ser.*, Vol. 1933, hal. 1-6, 2021.
- [32] (2021) "Pemerintah Terus Upayakan Pemulihan Ekonomi, Namun Tetap Waspada terhadap Pandemi Covid," [Online], <https://www.kemenkeu.go.id/publikasi/berita/pemerintah-terus-upayakan-pemulihan-ekonomi-namun-tetap-waspada-terhadap-pandemi-covid/>, tanggal akses: 20-Okt-2021.
- [33] N. Kalbuana, dkk., "Earnings Management is Affected by Firm Size, Leverage and ROA: Evidence from Indonesia," *Acad. Strateg. Manag. J.*, Vol. 20, Special Issue 2, hal. 1–12, 2021.
- [34] A. Nugroho (2020) "Daya Beli Sapi Potong di Masa Pandemi Turun," [Online], <https://ugm.ac.id/berita/19745-daya-beli-sapi-potong-di-masa-pandemi-turun>, tanggal akses: 20-Okt-2021.
- [35] P. Wicaksono (2020) "Harga Ayam Turun Akibat Corona, Peternak Minta Pemda Turun Tangan," [Online], <https://bisnis.tempo.co/read/1334069/harga-ayam-turun-akibat-corona-peternak-minta-pemda-turun-tangan/full&view=ok>, tanggal akses: 20-Okt-2021.