

Penerapan *Generalized Regression Neural Networks* untuk Memprediksi Produksi Padi Terhadap Perubahan Iklim

Muhammad Alkaff, Yuslena Sari

Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Lambung Mangkurat
Jl. Brigjen H. Hasan Basri, Kayu Tangi, Banjarmasin, Indonesia
m.alkaff@unlam.ac.id

Abstrak

Padi sebagai bahan makanan pokok utama bagi masyarakat Indonesia merupakan tanaman pangan yang rentan terhadap perubahan iklim. Pendataan dan perhitungan ramalan hasil produksi padi sangat diperlukan untuk mendukung kebijakan yang berkaitan dengan ketahanan pangan. Penelitian ini bertujuan untuk melakukan peramalan terhadap produksi padi di Kabupaten Barito Kuala sebagai kabupaten penghasil padi terbesar di Kalimantan Selatan dengan menggunakan data iklim sebagai *input*. Data iklim yang digunakan berasal dari Stasiun Meteorologi Syamsudin Noor, sedangkan sebagai data *output* adalah data produksi padi dari Badan Pusat Statistika (BPS) Provinsi Kalimantan Selatan. Metode yang digunakan untuk melakukan peramalan produksi padi adalah *Generalized Regression Neural Networks* (GRNN). Dari hasil pengujian didapatkan nilai *Root Mean Square Error* (RMSE) sebesar 0,296 dengan menggunakan parameter *smoothness* bernilai 1.

Kata kunci: padi, iklim, Barito Kuala, GRNN, RMSE

Abstract

Rice as the main staple food for the people of Indonesia is a crop that vulnerable to climate change. The data collection and forecasting of rice production is needed to support policies related to food security. This study aims to forecast the production of rice in Barito Kuala District as the largest rice-producing district in South Kalimantan using climate data as input. The climatic data used is from Syamsudin Noor Meteorological Station, while the output data is rice production data from Statistical Centre Agency of South Kalimantan Province. The method used to forecast rice production is Generalized Regression Neural Networkss (GRNN). RMSE value of 0.296 was obtained from the test results using smoothness parameter with a value of 1.

Keywords: rice, climate, Barito Kuala, GRNN, RMSE

I. PENDAHULUAN

Pangan merupakan kebutuhan dasar manusia yang tidak tergantikan. Pertumbuhan jumlah penduduk di Indonesia yang semakin meningkat tentu akan sangat memerlukan jumlah penyediaan pangan dalam jumlah yang sangat besar pula. Oleh karena itu, kemandirian pangan merupakan salah satu isu strategis nasional yang tercantum dalam Rencana Induk Riset Nasional 2015-2045. Permasalahan utama di bidang pangan selama ini adalah belum tercapainya swasembada pangan secara nasional, sehingga untuk menjamin ketersediaan pangan bagi warga negaranya, pemerintah terpaksa melakukan kebijakan impor [1].

Salah satu tantangan dalam penyediaan pangan adalah perubahan iklim. Perubahan iklim yang terjadi mengakibatkan periode musim hujan dan musim kemarau menjadi tidak menentu, sehingga pola tanam dan estimasi produksi pertanian serta persediaan stok pangan menjadi sulit diprediksi [2]. Hal ini dapat mempengaruhi ketahanan pangan dan produksi pertanian secara langsung maupun tidak langsung.

Tanaman pangan termasuk yang paling rentan terhadap perubahan iklim. Ini terkait tiga faktor utama, yaitu biofisik, genetik dan manajemen. Hal tersebut disebabkan karena tanaman pangan umumnya merupakan tanaman semusim yang relatif sensitif terhadap kelebihan dan kekurangan air [3].

Di Indonesia, tanaman pangan sering diidentikkan dengan beras karena jenis pangan ini merupakan makanan pokok utama bagi penduduk Indonesia. Beras merupakan hasil pengolahan dari padi yang dalam hal ini berarti juga rentan terhadap perubahan iklim.

Pendataan dan perhitungan ramalan hasil produksi tanaman pangan termasuk padi telah dilakukan setiap tahun oleh Badan Pusat Statistik (BPS) dengan menggunakan metode analisis regresi untuk peramalan luas panen dan *linear trend/exponential smoothing* untuk peramalan produktivitas tergantung pada pola datanya [4]. Penelitian lain melakukan prediksi luas panen dan produktivitas padi menggunakan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dengan tingkat akurasi peramalan yang dihasilkan dengan kriteria *Mean Absolute Percentage Error* (MAPE) sebesar 3,122 % [5]. Namun, metode-metode yang diterapkan tersebut belum mempertimbangkan *variable* perubahan iklim dalam perhitungannya.

Penelitian tentang prediksi produksi tanaman pangan di Indonesia yang menggunakan perubahan iklim sebagai parameternya juga telah dilakukan dengan menggunakan metode regresi linier berganda dengan akurasi prediksi sekitar 70% [6]. Model regresi linier berganda sebenarnya merupakan model yang sangat fleksibel untuk meneliti hubungan dari kumpulan variabel independen untuk variabel dependen tunggal [7]. Akan tetapi, ketika digunakan untuk memodelkan variabel iklim terhadap produksi padi, akurasi yang didapatkan masih belum terlalu akurat.

Metode yang umum digunakan untuk melakukan peramalan atau prediksi adalah metode jaringan syaraf tiruan. *Generalized Regression Neural Networks* (GRNN) merupakan salah satu model dari jaringan syaraf tiruan dengan menggunakan *supervised training* dimana *output* yang diharapkan diarahkan untuk mengikuti pola *output* data *training* [8]. Inti dari model GRNN didasarkan pada regresi *nonlinear* (kernel) dimana estimasi dari nilai *output* ditentukan oleh himpunan *input*-nya [9].

Provinsi Kalimantan Selatan sebagai salah satu lumbung padi nasional tentu diharapkan mampu untuk meningkatkan produksi pertaniannya terutama padi yang salah satunya berasal dari kabupaten penghasil padi terbesar di Kalimantan Selatan yaitu Kabupaten Barito Kuala. Dalam penelitian ini, digunakan metode GRNN untuk memodelkan pengaruh perubahan iklim terhadap produksi padi di Kabupaten Barito Kuala. Metode ini digunakan karena merupakan metode yang cocok untuk memodelkan pengaruh antara *variable input* yaitu perubahan iklim dan *variable output* yaitu produksi padi.

II. TINJAUAN PUSTAKA

Padi (*Oryza Sativa L.*) adalah tanaman pangan berupa rumput berumpun. Padi merupakan tanaman pangan utama di Indonesia karena beras yang diolah dari padi adalah makanan pokok bagi sebagian besar penduduk Indonesia. Padi dapat beradaptasi pada lingkungan tergenang (*anaerob*) karena pada akarnya terdapat saluran *aerenchyma*. Struktur *aerenchyma* seperti pipa yang memanjang hingga ujung daun. *Aerenchyma* berfungsi sebagai penyedia oksigen bagi daerah perakaran. Walaupun mampu beradaptasi pada lingkungan tergenang, padi juga dapat dibudidayakan pada lahan yang tidak tergenang (ladang) yang kondisinya *aerob*.


Sistem pembudidayaan tanaman padi di Indonesia secara garis besar dikelompokkan menjadi dua, yaitu padi sawah dan padi gogo (padi huma, padi ladang). Pada sistem sawah, tanaman padi sepanjang hidupnya selalu dalam keadaan tergenang air. Sebaliknya, pada sistem gogo, tanaman padi ditumbuhkan tidak dalam kondisi tergenang. Kombinasi kedua sistem ini dikenal sebagai gogo rancah, yaitu padi ditanam saat awal musim hujan pada petakan sawah, kemudian secara perlahan digenangi dengan air hujan seiring dengan makin bertambahnya curah hujan. Di daerah rawa, terutama Sumatera dan Kalimantan, dikenal sistem pengusahaan padi pasang surut (padi sonor), sedangkan pada daerah bantaran sungai dikenal budidaya padi lebak. Varietas padi yang digunakan adalah jenis yang mempunyai ruas-ruas batang yang panjang sehingga dapat beradaptasi dengan lingkungan banjir [10].

Antara unsur-unsur iklim terhadap tanaman tentu terjadi interaksi, pengaruh unsur-unsur iklim lingkungan terhadap tanaman menjadi penting dengan semakin besarnya dan banyaknya jumlah rumpun tanaman. Beberapa klasifikasi iklim didasarkan pada dunia tumbuh-tumbuhan sehingga ada hubungan erat antara pola iklim dengan distribusi tanaman. Tanaman dipandang sebagai suatu yang kompleks dan peka terhadap pengaruh iklim, misalnya kelembaban, pemanasan, penyinaran matahari dan lain-lain. Tanpa unsur-unsur iklim ini, pada umumnya pertumbuhan tanaman akan terhambat [6]. Untuk tanaman padi, faktor iklim yang dominan mempengaruhi produksi, luasan panen dan produktivitas padi adalah curah hujan. Artinya ketersediaan air akan sangat mempengaruhi produksi, luasan panen, dan produktivitas padi. Penyinaran matahari dan suhu mempunyai peran yang tidak besar terhadap peningkatan produksi, luasan panen, dan produktivitas, tetapi terdapat kecenderungan untuk meningkatkan produksi, luasan panen, dan

produktivitas padi. Sebaliknya, tingkat kelembaban yang tinggi akan menyebabkan penurunan produksi, luasan panen, dan produktivitas padi [11].

Artificial Neural Networks (ANN) merupakan paradigma pengolahan informasi yang terinspirasi oleh cara sistem saraf biologis, seperti bagaimana cara otak memproses informasi. Elemen kunci dari paradigma ini adalah struktur dari sistem pengolahan informasi. ANN terdiri dari sejumlah besar elemen pemrosesan yang saling berhubungan (*neuron*) dan saling berinteraksi untuk memecahkan masalah tertentu. ANN, seperti manusia pada umumnya, dapat belajar dari contoh yang sudah diberikan. ANN dapat dikonfigurasi untuk aplikasi tertentu, seperti pengenalan pola atau klasifikasi data, melalui proses pembelajaran. Peramalan atau prediksi juga merupakan kasus yang umum diaplikasikan ke ANN. Di dalam ANN, sebuah *neuron* diibaratkan sebagai sebuah simpul yang berfungsi sebagai elemen pemrosesan data. Hubungan antar simpul dalam ANN diperoleh dari bobot koneksi (*weight*) yang memodelkan sinapsis pada jaringan syaraf otak manusia. Gambar 1 memperlihatkan model sederhana dari ANN.

Proses pada ANN dimulai dari *input* yang diterima oleh *neuron* beserta dengan nilai bobot dari tiap-tiap *input* yang ada. Setelah masuk ke dalam *neuron*, nilai *input* akan dijumlahkan oleh suatu *summing function*. Hasil penjumlahan akan diproses oleh fungsi aktivasi setiap *neuron*, kemudian hasil penjumlahan akan dibandingkan dengan nilai *threshold* tertentu. Jika nilai tersebut melebihi *threshold*, maka aktivasi *neuron* akan dibatalkan, sebaliknya, jika nilai masih tersebut memenuhi *threshold*, maka *neuron* akan diaktifkan. Setelah aktif, *neuron* akan mengirimkan nilai *output* melalui bobot-bobot *output*-nya ke semua *neuron* yang berhubungan dengannya. Proses ini akan terus berulang pada *input-input* selanjutnya. ANN memiliki beberapa fitur yang membedakan dari metode-metode lain terutama untuk kasus peramalan/prediksi. Pertama, ANN merupakan model yang *data-driven* dan *self-adaptive* yang berarti model ini tidak memberikan asumsi apriori dan hanya belajar dari contoh-contoh yang diberikan, sehingga dapat menangkap hubungan



Gambar 1. Model *Artificial Neural Networks*

fungsional dari data walaupun kecil, bahkan jika hubungan antar data tersebut tidak berdasar dan sulit digambarkan. Oleh karena itu, ANN cocok untuk kasus dimana solusinya memerlukan pengetahuan yang sulit dispesifikasikan namun memiliki data yang cukup untuk diobservasi [12].

Proses belajar dari ANN dapat dibagi menjadi dua yaitu *supervised learning* dan *unsupervised learning*. *Supervised learning* merupakan suatu proses pembelajaran pada ANN dimana *output* yang diharapkan telah diketahui sebelumnya. Umumnya, proses pembelajaran ini dilakukan dengan menggunakan data *input* dan *output* yang digunakan sebagai data *training*. Pada metode ini, setiap pola yang diberikan kedalam ANN telah diketahui *output*-nya. Satu pola *input* akan diberikan ke satu *neuron* pada lapisan *input*. Pola ini akan dirambatkan di sepanjang jaringan syaraf hingga sampai ke *neuron* pada lapisan *output*. Lapisan *output* ini akan membangkitkan pola *output* yang akan dicocokkan dengan pola *output* targetnya. Ketika terjadi perbedaan antara pola *output* hasil pembelajaran dengan pola *output* target, maka akan terjadi *error*. Apabila nilai *error* ini masih cukup besar, artinya proses pembelajaran masih harus dilakukan lebih lanjut dengan proses iterasi. *Supervised learning* umumnya diaplikasikan untuk kasus peramalan atau prediksi. *Unsupervised learning* merupakan suatu proses pembelajaran pada ANN dimana *output* yang diharapkan tidak diketahui sebelumnya. Pada metode pembelajaran ini, tidak ditentukan *output* seperti apa yang diharapkan selama proses pembelajaran. Nilai bobot akan disusun dalam proses *range* tertentu tergantung pada nilai *output* yang diberikan. Tujuan metode *unsupervised learning* ini adalah agar dapat mengelompokkan unit-unit yang hampir sama dalam satu area tertentu. Proses pembelajaran ini umumnya sangat cocok diaplikasikan untuk kasus klasifikasi.

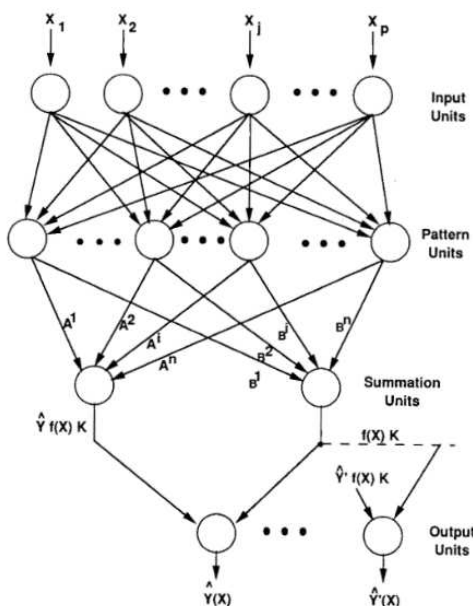
Generalized Regression Neural Networks (GRNN) merupakan salah satu model dari ANN dengan *supervised learning* dimana fungsi aktivasinya menggunakan *Radial Basis Function* (RBF). Metode ini umumnya digunakan untuk kasus peramalan/prediksi dimana variable *output*-nya dimodelkan berdasarkan minimal satu variabel *input*. GRNN didasarkan pada teori regresi *nonlinear* yang diformulasikan seperti pada persamaan (1) berikut.

$$E[y | X] = \frac{\int_{-\infty}^{\infty} yf(X, y)dy}{\int_{-\infty}^{\infty} f(X, y)dy} \quad (1)$$

dengan y merupakan *output* yang diprediksi oleh GRNN, sedangkan X merupakan vektor *input* (x_1, x_2, \dots, x_p) yang terdiri dari p variabel. $E[y|X]$ merupakan nilai harapan dari *output* y jika diberikan vektor *input* X , dan $f(X, y)$ merupakan fungsi densitas probabilitas bersama dari X dan Y . Metode akhir pada analisis *output* dari GRNN adalah menghitung keakuratan prediksi dengan menghitung persen variansi pada variabel *output* yang diterangkan oleh variabel *input* dengan menghitung MSE (*Mean Square Error*) [13].

Dalam proses optimasi GRNN, hanya satu parameter *smoothing* yang harus disesuaikan satu kali melalui data, sehingga tidak ada prosedur iterasi yang dilakukan pada GRNN. Estimasi parameter tersebut dibatasi oleh nilai minimum dan maksimum data. Selanjutnya, GRNN mendekati fungsi *arbitrary* antara vektor *input* dan vektor target. Keunggulan GRNN adalah proses belajar dan konvergensi yang cepat ke permukaan regresi optimal walaupun data *training* sangat besar jumlahnya [9]. Oleh karena itu, GRNN merupakan metode yang cocok untuk melakukan prediksi.

GRNN terdiri dari empat layer yaitu: *input layer*, *pattern layer*, *summation layer*, dan *output layer*. Jumlah *input* pada *input layer* tergantung pada jumlah parameter yang diobservasi. Layer pertama terhubung ke *pattern layer* dan pada layer ini setiap *neuron* memberikan pola *training* dan *output*-nya. *Pattern layer* kemudian terhubung dengan *summation layer*. *Summation layer* memiliki dua jenis penjumlahan berupa *single division unit* dan *summation units*. *Summation layer* dan *output layer* bersama akan melakukan normalisasi dari kumpulan *output* yang didapatkan [14]. Arsitektur dari GRNN dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur GRNN

III. METODE PENELITIAN

Data yang digunakan dalam penelitian ini berupa data sekunder yang diperoleh dari *website* Badan Meteorologi Klimatologi dan Geofisika (BMKG) tahun 2005-2016. Data tersebut berupa data iklim harian yang meliputi curah hujan, suhu minimum, suhu maksimum, suhu rata-rata, kelembaban rata-rata, dan lama penyinaran. Data iklim yang digunakan adalah data iklim yang didapatkan dari Stasiun Meteorologi Syamsudin Noor. Data iklim harian ini digunakan sebagai data *input* baik pada proses *training* maupun proses *testing*.

Data sekunder berikutnya adalah data produksi padi empat bulan (*subround*) yang meliputi luas panen, produksi, dan produktivitas padi tahun 2005-2016 di Kabupaten Barito Kuala. Data tersebut diperoleh dari Dinas Pertanian Tanaman Pangan dan Hortikultura Provinsi Kalimantan Selatan. Data produksi padi ini digunakan sebagai data *output* baik pada proses *training* maupun proses *testing*.

Data sekunder ini dibagi menjadi data *training* dan data *testing*. Untuk data *training* digunakan data iklim harian dan produksi padi selama 8 tahun, yaitu data dari tahun 2005-2013. Untuk data *testing* digunakan data iklim harian dan produksi padi selama tiga tahun pada tahun 2014-2016.

Agar data data iklim harian dan produksi padi kabupaten Barito Kuala dapat digunakan sebagai *input* dari GRNN, data tersebut harus dilakukan *preprocessing* terlebih dahulu. Pertama, data akan dibagi menjadi data *training* dan data *testing*. Data iklim harian dari tahun 2005 sampai dengan tahun 2012 digunakan sebagai *input* dari data *training*. Kemudian data produksi padi tahun 2005 sampai dengan tahun 2012 dipetakan sebagai *output* dari data *training*. Data iklim harian tahun 2013 tidak dapat digunakan sebagai data *input training* dikarenakan banyaknya data iklim harian yang kosong.

Selanjutnya, hal yang sama juga akan dilakukan untuk data pengujian dimana data iklim harian tahun 2014 sampai dengan 2016 digunakan sebagai *input* untuk data uji dan data produksi padi tahun 2014 sampai dengan 2016 digunakan sebagai *output* untuk data uji.

Pengolahan data selanjutnya adalah untuk menyesuaikan format waktu pada data *input*. Hal ini dikarenakan data iklim sebagai data *input* memiliki format harian, sedangkan untuk data produksi padi memiliki format empat bulanan. Dengan demikian, data iklim yang akan digunakan sebagai *input* harus disesuaikan terlebih dahulu agar mempermudah dalam proses pemetaan pola iklim terhadap produksi padi. Data iklim harian dikumpulkan sebagai data *input* sebanyak 90 hari yang

perhitungan waktunya diasumsikan setara dengan tiga bulan, sehingga dapat dipetakan dengan data produksi sawah bulan berikutnya yang memiliki format waktu empat bulanan. Disebabkan terdapat banyak data iklim harian yang kosong (*missing data*), maka untuk mengatasi hal tersebut digunakan teknik imputasi terhadap data agar tidak ada data yang dibuang, sehingga dapat mengurangi jumlah data *input*. Strategi imputasi dilakukan dengan menggunakan nilai rata-rata untuk mengisi data yang kosong pada data iklim harian.

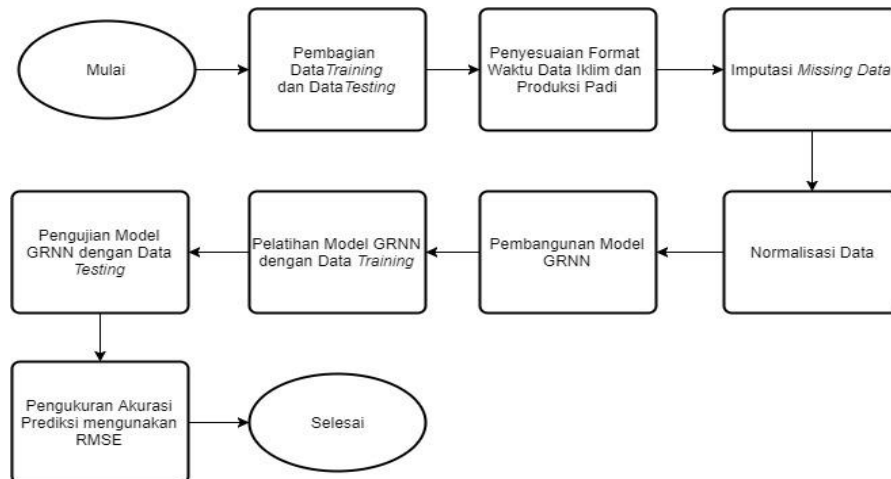
Selanjutnya, sebelum dapat digunakan sebagai *input* untuk GRNN, data tersebut diolah kembali dengan menggunakan skala minimum dan maksimum sehingga *range* semua data akan berkisar antara 0 sampai dengan 1. Selanjutnya setelah data diolah, maka data iklim harian akan dapat digunakan sebagai data *input* untuk memetakan data *output* yaitu produksi padi per empat bulan menggunakan GRNN. Pada Gambar 3 dapat dilihat bagan alur dari penelitian.

Proses *training* dilakukan dengan menggunakan 24 data *training* yaitu data *input* iklim harian selama 90 hari. Penggunaan data iklim harian selama 90 hari atau kurang lebih sama dengan tiga bulan digunakan untuk membangun model prediksi produksi padi satu bulan setelahnya. Data iklim harian tersebut kemudian dipetakan dengan data *output* berupa data produksi padi per empat bulan selama rentang waktu 8 tahun yaitu dari tahun 2005 sampai dengan tahun 2012. Gambar 4 menunjukkan arsitektur dari model GRNN yang dibangun.

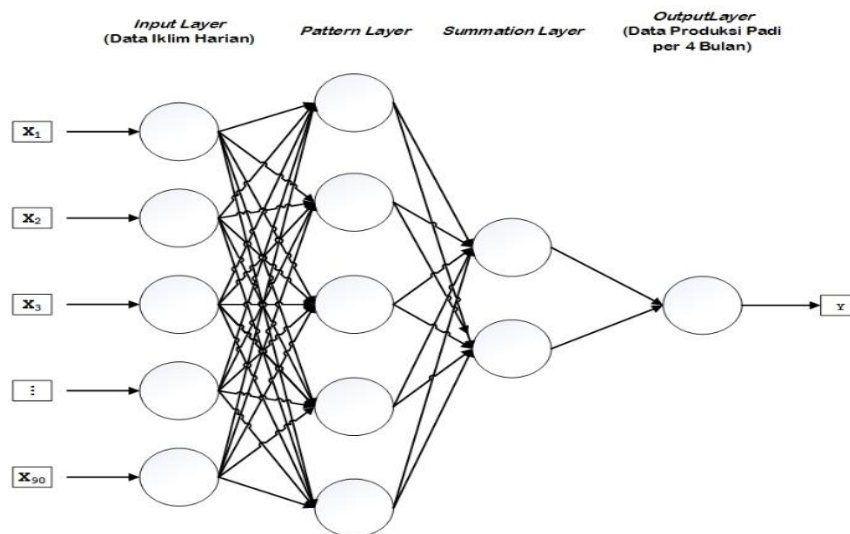
Proses *training* dan pengujian model dilakukan dengan spesifikasi perangkat keras dan perangkat lunak seperti pada Tabel 1 berikut.

Tabel 1. Waktu Komputasi Proses *Training* GRNN

Perangkat	Spesifikasi
Prosesor	AMD FX-6300 6 Core Processor
Memori	RAM 8 GB
Sistem Operasi	Microsoft Windows 10 64-bit
Pemrograman	Python 2.7.11



Gambar 3. Bagan alur penelitian



Gambar 4. Arsitek model GRNN yang dibangun

IV. HASIL DAN PEMBAHASAN

Pengujian pertama dilakukan untuk melihat waktu komputasi pada proses *training* dengan menggunakan nilai parameter *smoothness* sebesar 0,5, 0,75, dan 1. Waktu komputasi proses *training* dapat dilihat pada Tabel 2 berikut.

Beberapa penelitian sebelumnya tidak menyebutkan data tentang waktu komputasi yang dibutuhkan dalam memproses data iklim yang digunakan. Dari Tabel 2 dapat dilihat kelebihan dari metode GRNN yaitu proses *training* cepat yang tidak memerlukan iterasi dalam proses *training*-nya [10]. Dari Tabel 2 juga terlihat bahwa parameter *smoothness* cukup mempengaruhi waktu dari proses *training* yang dilakukan walaupun perbedaan waktunya tidak terlalu signifikan.

Selanjutnya, hasil dari proses *training* yang telah dilakukan akan diuji dengan menggunakan data *testing*. Pengujian terhadap model yang telah dibangun dilakukan dengan menggunakan parameter *smoothness* dengan nilai masing-masing 0,5, 0,75, dan 1. Guna mendapatkan model prediksi yang terbaik, hasil prediksi akan dibandingkan dengan nilai *output* sebenarnya (*real value*). Kemudian, hasil dari model tersebut akan diukur RMSE-nya (*Root Mean Square Error*) untuk mengetahui akurasi dari prediksi yang telah didapatkan pada model hasil *training* untuk tiap parameter *spread*. Nilai RMSE yang didapatkan dapat dilihat pada Tabel 3.

Tabel 2. Waktu komputasi proses *training* GRNN

Percobaan ke-	<i>Smoothness</i>	Waktu(detik)
1	0,5	$6,525 \times 10^{-5}$
2	0,5	$6,058 \times 10^{-5}$
3	0,5	$6,087 \times 10^{-5}$
Rerata waktu		$6,224 \times 10^{-5}$
1	0,75	$5,883 \times 10^{-5}$
2	0,75	$6,058 \times 10^{-5}$
3	0,75	$6,087 \times 10^{-5}$
Rerata waktu		$6,010 \times 10^{-5}$
1	1	$6,029 \times 10^{-5}$
2	1	$5,971 \times 10^{-5}$
3	1	$5,971 \times 10^{-5}$
Rerata waktu		$5,991 \times 10^{-5}$

Tabel 3. Nilai RMSE model prediksi dengan GRNN

<i>Smoothness</i>	RMSE
0,5	0,375
0,75	0,326
1	0,296

Dari Tabel 3 di atas dapat terlihat bahwa nilai RMSE yang didapatkan yaitu 0,375 untuk parameter *smoothness* bernilai 0,5, selanjutnya nilai RMSE 0,326 untuk parameter *smoothness* 0,75. Untuk nilai RMSE terendah didapatkan model dengan parameter *smoothness* bernilai 1 yaitu sebesar 0,296.

Hal ini mungkin diakibatkan antara lain karena kompleksnya pemetaan yang dilakukan, dimana data iklim harian selama 90 hari (tiga bulan) dipetakan ke satu *output* produksi padi per empat bulan. Hal ini tidak dialami oleh [7], karena penelitian tersebut menggunakan data iklim bulanan. Kurangnya data *training* yang berjumlah 24 pasang data *input* dan data *output* dikarenakan data produksi padi yang digunakan adalah data per empat bulan yang dikumpulkan selama enam tahun. Banyaknya *missing value* (data yang tidak ada nilainya) pada data iklim harian yang didapatkan dari *website* BMKG pada data *input* nampaknya juga sangat mempengaruhi model yang dibangun. Hal ini dapat dimaklumi karena BMKG memang baru memulai untuk menyediakan data-data iklim harian untuk digunakan oleh masyarakat umum maupun peneliti khususnya.

V. KESIMPULAN

Penerapan *Generalized Regression Neural Networks* (GRNN) untuk memprediksi produksi padi terhadap perubahan iklim telah dapat menghasilkan hasil akurasi yang cukup baik berdasarkan nilai RMSE yang didapatkan yaitu 0,296 dengan parameter *smoothness* bernilai 1. Akurasi dari model prediksi dapat ditingkatkan dengan cara menggunakan data iklim yang tidak mengandung *missing value*. Dari waktu komputasi dapat disimpulkan bahwa GRNN memiliki proses konvergensi yang cepat sehingga proses *training* dapat dilakukan dengan singkat. Semakin besar nilai parameter *smoothness* maka proses *training* menjadi lebih cepat, walaupun perbedaan waktunya tidak terlalu signifikan.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Fakultas Teknik Universitas Lambung Mangkurat atas bantuan dana yang telah diberikan melalui dana DIPA PNPB Universitas Lambung Mangkurat sehingga penelitian ini dapat terlaksana sebagaimana mestinya.

REFERENSI

- [1] Ristekdikti, “Rencana induk riset nasional 2015-2040,” *Kemenristekdikti Republik Indonesia. Jakarta*, vol. 2045, p. 58, 2016.
- [2] Universitas Lambung Mangkurat, “Rencana Induk Penelitian Universitas Lambung Mangkurat,” 2011.
- [3] R. Asnawi, “Perubahan Iklim dan Kedaulatan Pangan di Indonesia. Tinjauan Produksi dan Kemiskinan,” *Sosio Inf.*, vol. 1, no. 3, pp. 293–309, 2015.
- [4] BPS, “Produksi Tanaman Pangan. Angka Ramalan II tahun 2015,” p. 68, 2015.
- [5] Supriyanto, Sudjono, and D. Rakhmawati, “Prediksi Luas Panen dan Produksi Padi di Kabupaten Banyumas Menggunakan Metode Adaptive Neuro-Fuzzy Inference System (ANFIS),” *J. Probisnis*, vol. 5, no. 2, pp. 20–29, 2012.
- [6] A. N. Arifin, H. Halide, and N. Hasanah, “Prediksi Probabilitas Produktivitas Tanaman Pangan di Kota Makassar Berbasis Iklim,” Universitas Hasanuddin, 2013.
- [7] L. Aiken, S. West, and S. Pitts, *Multiple linear regression*. 2003.
- [8] B. Warsito, T. Tarno, and A. Sugiharto, “Prediksi Curah Hujan Sebagai Dasar Perencanaan Pola Tanam Padi Dan Palawija Menggunakan Model General Regression Neural Network,” *J. LITBANG Provinsi*, 2009.
- [9] D. F. Specht, “A general regression neural network,” *Neural Networks, IEEE Trans.*, vol. 2, no. 6, pp. 568–576, 1991.
- [10] P. Purwono and H. Purnamawati, “Budidaya 8 jenis tanaman pangan unggul,” *Penebar Swadaya. Jakarta*, 2007.
- [11] N. Khodijah, “Hubungan Antara Perubahan Iklim Dan Produksi Tanaman Padi Di Lahan Rawa Sumatera Selatan,” *Enviagro, J. Pertan. dan Lingkung.*, vol. 8, no. 2, pp. 83–91, 2015.
- [12] B. Guoqiang Zhang and M. Y. H. Eddy Patuwo, “Forecasting with *Artificial Neural Networks*: The state of the art,” *Int. J. Forecast.*, vol. 14, pp. 35–62, 1998.
- [13] L. Adnyani and S. Subanar, “General Regression Neural Network (GRNN) pada Peramalan Kurs Dolar dan Indeks Harga Saham Gabungan (IHSG),” *Fakt. Exacta*, 2015.
- [14] S. A. Hannan, R. R. Manza, and R. J. Ramteke, “*Generalized Regression Neural Networks* and Radial Basis Function for Heart Disease Diagnosis,” *Int. J. Comput. Appl.*, vol. 7, no. 13, pp. 975–8887, 2010.

