



Artikel

Penerapan Algoritma Propagasi Balik Jaringan Saraf Tiruan untuk Prediksi Produksi Sumur Gas di Sumatera Bagian Selatan

Rofingi Aji ¹, Yanuar Zulardiansyah Arief ^{1,*}, Sinka Wilyanti ¹, Rosyid Ridlo Al-Hakim ², Muhammad Yusro ³, dan Rian Ardianto ⁴

¹ Departemen Teknik Elektro, Jakarta Global University, Depok, Indonesia

² Departemen Sistem Informasi, Universitas Harapan Bangsa, Purwokerto, Indonesia

³ Departemen Pendidikan Teknik Elektronika, Universitas Negeri Jakarta, Jakarta, Indonesia

⁴ Departemen Informatika, Universitas Harapan Bangsa, Purwokerto, Indonesia

* Korespondensi: yanuar@jgu.ac.id

Abstrak: Prediksi produksi gas merupakan langkah penting untuk mendukung perencanaan dan pengelolaan sektor energi minyak dan gas (migas) suatu negara atau wilayah. *Artificial Neural Network* (ANN) termasuk metode yang efektif untuk melakukan prediksi, namun tantangannya adalah menentukan jumlah neuron dan *hidden layer* yang optimal agar akurasi prediksi tinggi. Penelitian ini bertujuan merancang arsitektur ANN dengan algoritma *backpropagation* untuk memprediksi produksi sumur gas. Tahapan penelitian meliputi pengumpulan data produksi gas, *pre-processing data*, pemrosesan prediksi, pengujian akurasi dan *error*, serta implementasi. Data penelitian mencakup catatan produksi harian sumur gas alam dari Januari hingga Desember 2022, yang digunakan sebagai dataset pelatihan dan pengujian model. Hasil penelitian menunjukkan bahwa arsitektur ANN 16-4-1 dengan fungsi aktivasi *sigmoid* menghasilkan akurasi terbaik sebesar 99,978% dan nilai MAPE terendah sebesar 2,192%. Temuan ini menunjukkan bahwa model yang dihasilkan mampu merepresentasikan pola kompleksitas data historis produksi harian secara akurat, sehingga dapat dimanfaatkan oleh pengelola lapangan migas untuk perencanaan produksi, optimasi operasi, dan pengambilan keputusan strategis di sektor energi.

Kata kunci: *artificial neural network*; *backpropagation*; energi; kecerdasan artifisial; peramalan.

Received: 24 Februari 2025

Revised: 31 Maret 2025

Accepted: 30 April 2025

Published: 6 Mei 2025



Copyright: © 2023 by the authors.

License Universitas Harapan Bangsa,

Purwokerto, Indonesia. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license

(<https://creativecommons.org/licenses/by/4.0>)

Pendahuluan

Sumatera bagian Selatan merupakan wilayah di Pulau Sumatera, Indonesia, yang memiliki prospek signifikan untuk pengembangan sumur produksi gas (Sutama & Inayah, 2013). Prediksi produksi gas memegang peranan penting dalam perencanaan, pengelolaan sumber daya, dan keberlanjutan pasokan energi (H. Liu et al., 2023a; Szoplik & Muchel, 2023). Berbagai studi sebelumnya telah menunjukkan potensi produktivitas sumur gas di wilayah ini yang cukup menjanjikan (Hennings et al., 2012; Zhang et al., 2017). Salah satu perusahaan yang beroperasi di daerah ini, yaitu *Oil and Gas Company*, telah melakukan aktivitas produksi gas alam selama lebih dari sepuluh tahun. Namun, dalam praktiknya, penentuan target produksi sumur masih dilakukan secara manual tanpa dukungan sistem peramalan yang memadai.

Namun, permasalahan utama dalam industri produksi gas adalah data produksi yang di hasilkan selama ini hanya dalam rekord saja, sehingga prediksi ke depan dalam produksi gas tidak terprediksi dengan baik (Fan et al., 2021). Ketiadaan sistem prediksi yang akurat menimbulkan sejumlah kendala, antara lain sulitnya memperkirakan kebutuhan pengembangan fasilitas pengolahan gas di masa depan (X. Liu et al., 2023) dan rendahnya kemampuan memproyeksikan produksi harian yang fluktuatif (Gonzalez et al., 2020). Padahal, peramalan yang tepat sangat dibutuhkan untuk mengoptimalkan operasi dan mengantisipasi penurunan produksi (Fan et al., 2021). Hal ini sejalan dengan pentingnya prediksi yang akurat guna menunjang pembangunan sektor energi migas suatu negara (Fry et al., 2017).

Perkembangan teknologi telah membawa kemajuan signifikan dalam berbagai bidang, termasuk sektor energi (Abu et al., 2023; Ali et al., 2023; Nagar et al., 2023). Dalam konteks prediksi produksi gas, penerapan metode berbasis *Artificial Neural Network* (ANN) mulai banyak dilirik karena kemampuannya dalam mengenali pola kompleks pada data historis produksi (Ayu et al., 2016; Nourislam et al., 2014). Kemajuan komputasi dan ketersediaan data dalam jumlah besar telah mendorong pengembangan model prediksi gas yang lebih akurat (Dong et al., 2023). Penelitian terkini menunjukkan bahwa penggunaan ANN dengan algoritma *backpropagation* mampu memberikan hasil prediksi yang lebih mendekati nilai aktual dibanding metode konvensional (Glushchenko et al., 2021; Vlachas et al., 2020).

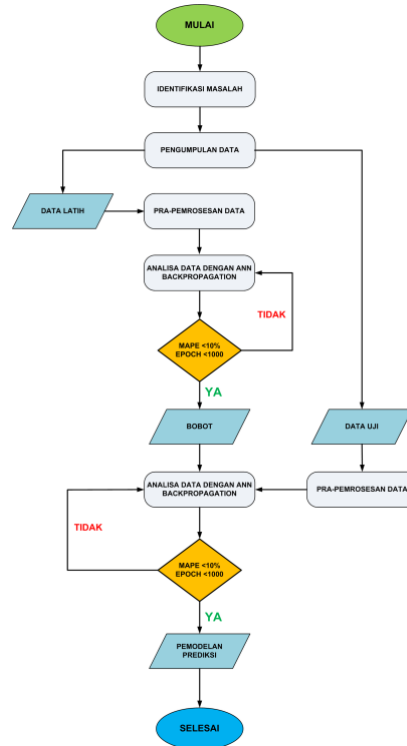
Secara konseptual, ANN merupakan sistem pemrosesan informasi yang terinspirasi dari jaringan saraf biologis dan memiliki kemampuan untuk melakukan pembelajaran dari data berukuran besar, mentoleransi kesalahan, dan menghasilkan prediksi yang andal (Herdiansah et al., 2022; Purnawan et al., 2024). Masalah utamanya adalah menentukan jumlah neuron dan *hidden layer* yang optimal untuk mencapai akurasi tinggi (Veri et al., 2022). ANN sendiri merupakan model matematika yang terinspirasi dari jaringan saraf manusia dan dapat digunakan untuk memodelkan hubungan kompleks antara *input* dan *output* (Puspitaningrum, 2006). Algoritma *backpropagation* sendiri berfungsi melatih jaringan dengan menghitung gradien fungsi kesalahan dan memperbarui bobot jaringan (Goh, 1995; Hecht-Nielsen, 1992; Wong, 1991; Wythoff, 1993). Berbagai studi telah membuktikan keberhasilan teknik ini pada prediksi produksi gas di berbagai negara, termasuk di China (H. Liu et al., 2023b).

Berdasarkan latar belakang tersebut, penelitian ini menerapkan metode ANN dengan algoritma *backpropagation* untuk kasus prediksi produksi gas di *Oil and Gas Company* di Sumatera bagian Selatan. Penelitian ini diarahkan untuk: (1) merancang arsitektur ANN yang optimal untuk prediksi produksi sumur gas; (2) menguji tingkat akurasi dan kesalahan prediksi; serta (3) mengevaluasi potensi penerapan metode ini sebagai alat bantu perencanaan dan pengambilan keputusan di sektor energi. Dengan pendekatan ini, diharapkan model yang dihasilkan dapat meningkatkan efektivitas pengelolaan produksi gas dan mendukung perencanaan strategis di masa depan.

Metode

Diagram Alir

Gambar 1 merupakan gambaran diagram alir yang disarankan untuk penelitian ini untuk menggambarkan proses pemodelan peramalan produksi gas alam.



Gambar 1. Diagram alir penelitian

Alur penelitian diawali dengan identifikasi masalah, terdiri atas tahap studi literatur dan perumusan masalah (dijelaskan dalam latar belakang penelitian), dilanjutkan dengan tahapan pengumpulan data, dilanjutkan dengan pra-pemrosesan data untuk dasar normalisasi data, setelahnya dilanjutkan dengan analisis data berupa pemodelan jaringan saraf tiruan (JST) yang terdiri atas pemodelan jaringan pada data latih dan data uji, tahapan akan diulangi kembali pada tahap pra-pemrosesan data jika syarat yang didapatkan tidak memenuhi, namun jika syarat yang didapatkan memenuhi maka penelitian dilanjut pada tahap berikutnya berupa pemodelan prediksi. Penelitian diakhiri setelah seluruh tahapan dalam diagram alir penelitian selesai.

Pengumpulan Data

Data yang dikumpulkan berupa set data produksi gas alam di 59 sumur milik perusahaan minyak dan gas bumi Indonesia di wilayah Sumatera bagian Selatan. Jenis set data berupa *time-series* dengan kurun waktu produksi antara bulan Januari sampai dengan Desember 2022 (1 tahun). Jika ada sumur yang memiliki nilai produksi nihil atau *null* pada sebagian tanggal, akan diabaikan.

Pra-Pemrosesan Data

Data yang dikumpulkan terlebih dahulu dilakukan persiapan data (*pre-processing data*) untuk normalisasi bentuk data. Data produksi sumur gas alam yang dikumpulkan sangat bervariasi nilainya, termasuk nilai nihil akan diabaikan, hal ini untuk memastikan tidak ada data yang hilang atau kosong lainnya yang perlu ditangani. Jika ada sumur yang memiliki nilai produksi 0.00, sumur tersebut akan di-include ke dalam analisis. Hal ini dengan pertimbangan nilai 0.00 sebagai nilai produksi yang valid (terdapat aktivitas produksi, hanya saja nilai produksinya yang zero).

Normalisasi data perlu dilakukan untuk menghindari hambatan dalam proses pemodelan peramalan produksinya, seperti mempertimbangkan nilai yang kosong atau nihil, sehingga hal ini menjadi dasar perlunya dilakukan normalisasi data dengan tahapan *pre-processing data*. Baik data uji maupun data latih akan melalui tahapan *pre-processing data*. Proses *pre-processing data* dilakukan menggunakan Persamaan 1.

$$\text{Set data} = \left(\frac{\text{data terpilih} - \text{nilai minimal}}{\text{nilai maksimal} - \text{nilai minimal}} \right) \times (0,9 - 0,1) + 0,1 \quad (1)$$

Analisis Data

Analisis data dilakukan dengan pemodelan jaringan saraf tiruan (JST) yang menggunakan perangkat lunak MATLAB versi R2012b dengan fitur *neural network (nn)*. Salah satu *output* dari pengujian data latih adalah nilai *Mean Squared Error (MSE)* (Persamaan 2), di mana dalam MATLAB itu sendiri, *output* pengujian *neural network* tidak tersedia sintak MAPE itu sendiri, sehingga penulis menggunakan kalkulasi nilai MAPE setelah mendapatkan nilai MSE sebagai acuan, dengan Persamaan 3 sebagai berikut.

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n} \times 100 \quad (2)$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|}{n} \times 100 \quad (3)$$

Dimana:

- n = jumlah data (sampel),
- A_t = nilai asli pada set data untuk t waktu,
- F_t = nilai prediksi pada t waktu,
- t = waktu data (hari).

MSE adalah metrik kesalahan yang paling umum digunakan. Ini menghukum kesalahan yang lebih besar karena mengkuadratkan angka yang lebih besar memiliki dampak yang lebih besar daripada mengkuadratkan angka yang lebih kecil. MSE adalah jumlah kesalahan kuadrat dibagi dengan jumlah data. MAPE sendiri adalah rata-rata kesalahan absolut dibagi dengan nilai pengamatan aktual. MAPE tidak boleh digunakan jika ada nol atau mendekati nol dalam data aktual.

Setelah data latih dilakukan normalisasi pada tahap *pre-processing*, selanjutnya akan dilakukan pemodelan jaringan saraf tiruan (JST) dengan metode propagasi balik. Data akan dimodelkan jaringannya dengan nilai *epoch* < 1000 sampai mendapatkan nilai MAPE < 10% (kategori kemampuan peramalan sangat baik). Selanjutnya jika memenuhi syarat ini, tahap berikutnya berupa pemodelan jaringan data ujinya.

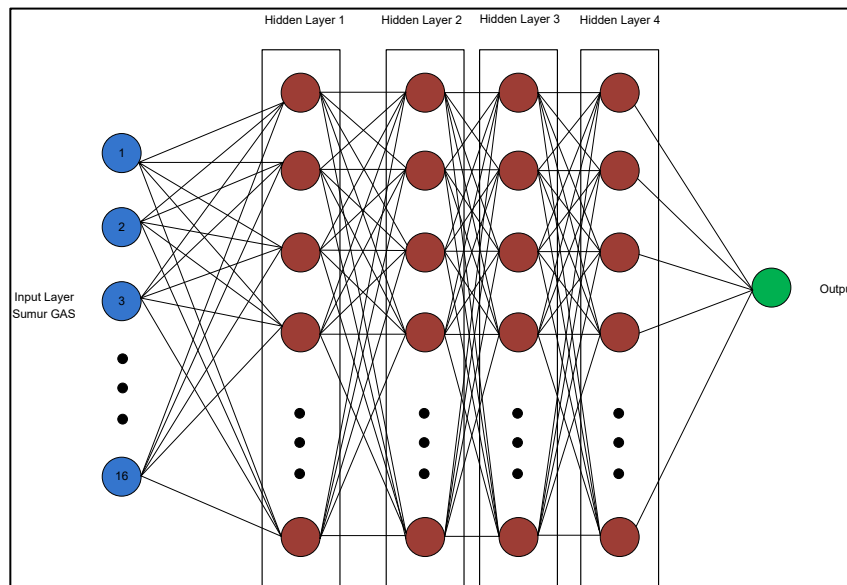
Setelah data latih didapatkan nilai MAPE < 10% dan model jaringannya, serta data uji telah dilakukan normalisasi pada tahap *pre-processing*, selanjutnya akan dilakukan pemodelan jaringan saraf tiruan (JST) dengan metode propagasi balik pada data ujinya. Data akan dimodelkan jaringannya dengan nilai *epoch* kurang dari 1000 sampai mendapatkan nilai MAPE < 10% (kategori kemampuan peramalan sangat baik). Selanjutnya jika memenuhi syarat ini, tahap berikutnya berupa pemodelan prediksi produksi gas alam. Model prediksi produksi gas alam yang dirancang adalah berdasarkan nilai MAPE terendah dengan jumlah *layer* terbaik, sehingga analisis peramalan akan mendapatkan nilai akurasi prediksi yang diharapkan, yaitu dalam kategori baik atau sangat baik.

Hasil dan Pembahasan

Skenario dengan Jumlah *Hidden Layer* Tertentu


Penulis awalnya memilih jumlah *hidden layer* di bawah 4 (1, 2, dan 3), namun hasil yang diperoleh menunjukkan nilai R yang rendah yakni semua di bawah 50. Selain itu, algoritma pelatihan yang digunakan pada awalnya "*traingd*", penulis mencoba melakukan pengujian *training data* ulang dengan jumlah *hidden layer* di atas 3, dan dimulai dari 4, 6, dan 8, serta algoritma pelatihan yang diubah menjadi "*trainlm*" (algoritma pelatihan "*traingd*" tetap memberikan pengaruh pada nilai R yang rendah meskipun jumlah *hidden layer* ditingkatkan terus-menerus). Skenario ini didasarkan pada evaluasi parameter hasil pengujian yang diharapkan dapat meningkat dari skenario awal, sehingga dapat memberikan model prediksi terbaik nantinya. Gambar 2 merupakan hasil uji "*training data*" menggunakan JST metode propagasi balik dengan jumlah *hidden layer* sebanyak 4 buah.

Jumlah *hidden layer* (neuron) pertama yang diajukan berjumlah empat (4). Pada metode propagasi balik (*backpropagation*) dalam *neural network*, fungsi aktivasi sigmoid sering digunakan untuk menghubungkan setiap neuron pada satu layer dengan neuron pada layer berikutnya. Sebagai fungsi aktivasi, sigmoid memberikan *output* yang berada dalam rentang 0 hingga 1, sehingga cocok untuk masalah klasifikasi biner atau regresi. Disisi lain, dengan jumlah *hidden layer* 4 ini masih dirasa kurang. Jumlah *hidden layer* yang lebih besar dapat membantu model mengekstraksi dan merepresentasikan pola-pola yang kompleks dalam data *input*, hal ini dapat meningkatkan kemampuan prediktif model.




Gambar 2. Skenario arsitektur 4 *hidden layer*.

Dengan menggunakan fungsi aktivasi sigmoid pada model prediksi ini, dapat mencapai nilai korelasi (R) sebesar 0,69683. Nilai R ini menunjukkan tingkat hubungan antara prediksi yang dihasilkan oleh model dengan data aktual. Semakin tinggi nilai R, semakin baik model dalam melakukan prediksi. Selain itu, kondisi *training state* yang dihasilkan cukup efisien dengan jumlah *epochs* yang relatif rendah, serta MSE yang rendah, semua menunjukkan bahwa model dengan 4 *hidden layer* dapat memberikan prediksi yang akurat dan dapat diandalkan, namun masih perlu ditingkatkan. Atas dasar ini, penulis meningkatkan jumlah *hidden layer* menjadi 6. Gambar 3 merupakan hasil uji “*training data*” menggunakan JST metode propagasi balik dengan jumlah *hidden layer* sebanyak 6 buah.



Gambar 3. Skenario arsitektur 6 *hidden layer*.

Setelah meningkatkan jumlah *hidden layer* menjadi 6 pada model prediksi, nilai korelasi (R) menurun sedikit menjadi 0,69665, dan nilai MSE sedikit meningkat menjadi 0,091385 dengan menggunakan 1000 *epochs*. Meskipun terjadi penurunan sedikit pada nilai R, model ini masih memiliki kemampuan prediktif yang baik dengan tingkat kesalahan yang tetap rendah (MSE). Hal ini menunjukkan bahwa penambahan *hidden layer* dapat membantu model dalam menggali pola-pola yang lebih kompleks dalam data *input*. Namun, perubahan ini perlu dievaluasi lebih lanjut dengan menggunakan lebih banyak pengujian yang lebih komprehensif untuk memastikan peningkatan performa model, salah satunya penambahan jumlah *hidden layer*. Gambar 4 merupakan hasil uji “*training data*” menggunakan JST metode propagasi balik dengan jumlah *hidden layer* sebanyak 8 buah.



Gambar 4. Skenario arsitektur 8 *hidden layer*.

Setelah melakukan peningkatan jumlah *hidden layer* menjadi 8 pada model prediksi, terjadi penurunan yang sangat kecil pada nilai korelasi (R) menjadi 0,69661, dan nilai MSE mengalami kenaikan kecil menjadi 0,091392 pada 465 *epochs* dari total 1000 *epochs*.

Hasil Pengujian Akurasi dengan Semua *Hidden Layer*

Tabel 1 merupakan hasil uji “*testing data*” menggunakan JST metode propagasi balik dengan masing-masing jumlah *hidden layer* sebanyak 4, 6, dan 8 buah terhadap “*training data*” yang telah diuji sebelumnya untuk mendapatkan nilai akurasi terbaik.

Tabel 1. Hasil pemodelan prediksi akurasi dengan berbagai jumlah *hidden layer*.

<i>Hidden Layer</i>	<i>Learning Rate</i>	R (%)	MSE	MAPE (%)	Akurasi (%)
4	0,01	69,683	0,091360	2,191780822	99,97808219
6	0,01	69,665	0,091385	4,678900000	99,95321100
8	0,01	69,661	0,091392	9,875700000	99,90124300

Berdasarkan hasil uji “*testing data*” dengan masing-masing jumlah *hidden layer* sebanyak 4, 6, dan 8 buah, performa model prediksi terbaik ada pada arsitektur 4 *hidden layer* dengan persentase akurasi tertinggi (99,97808219 %) dan nilai MAPE terendah (2,191780822 %).

Prediksi Produksi Gas Berdasarkan Model Jaringan Saraf

Berdasarkan hasil penelitian, prediksi produksi gas alam menggunakan model jaringan saraf propagasi balik menunjukkan hasil yang sangat memuaskan. Arsitektur layer jaringan saraf yang digunakan adalah 16-4-1, dengan fokus pada prediksi produksi pada tiga sumur paling produktif, yaitu sumur dengan kode G02, G50, dan G59. Hasil prediksi yang di uji coba-kan untuk tiga tahun (2025, 2026, dan 2027) menunjukkan nilai produksi gas

alam per bulan selama satu tahun untuk total ketiga sumur terproduktif yang diteliti, diukur dalam satuan MMSCFD (Tabel 2).

Tabel 2. Hasil prediksi ketiga sumur berdasarkan model jaringan saraf tiruan yang diusulkan.

Tahun	Hasil Prediksi Ketiga Sumur Terproduktif "G02, G50, dan G59" (MMSCFD)
2025	135,808
2026	141,624
2027	155,103

Tingkat akurasi hasil prediksi yang diperoleh mencapai 99,97808219 %, menandakan bahwa model jaringan saraf tiruan mampu dengan sangat baik memodelkan dan memprediksi pola produksi gas alam dari ketiga sumur tersebut. Hasil ini memberikan keyakinan yang tinggi dalam penggunaan teknik jaringan saraf tiruan untuk meramalkan produksi gas alam dengan akurasi yang tinggi, yang dapat memberikan manfaat besar dalam perencanaan dan pengelolaan sumber daya energi.

Kesimpulan

Berdasarkan hasil penelitian, arsitektur *Artificial Neural Network* (ANN) terbaik untuk prediksi produksi sumur gas adalah 16-4-1, yaitu 16 neuron pada *input layer*, 4 neuron pada *hidden layer*, dan 1 neuron pada *output layer*. Model ini, dengan fungsi aktivasi *sigmoid*, menghasilkan tingkat akurasi sebesar 99,978% dan nilai MAPE terendah 2,192%, sehingga mampu merepresentasikan kompleksitas data historis produksi harian sumur gas periode Januari–Desember 2022 secara akurat.

Hasil ini menjawab tujuan penelitian dengan menunjukkan bahwa: (1) arsitektur ANN optimal telah dirancang untuk memprediksi produksi sumur gas; (2) pengujian akurasi dan kesalahan prediksi menunjukkan performa sangat tinggi; dan (3) model terbukti memiliki potensi sebagai alat bantu perencanaan dan pengambilan keputusan di sektor energi.

Secara praktis, model ini dapat dimanfaatkan oleh perusahaan migas untuk memperkirakan produksi harian secara lebih akurat, mengoptimalkan pengelolaan sumber daya, menentukan kebutuhan pengembangan fasilitas pengolahan gas, serta mendukung strategi produksi jangka panjang yang lebih efisien dan berkelanjutan.

Referensi

- Abu, S. M., Hannan, M. A., Ker, P. J., Mansor, M., Tiong, S. K., & Mahlia, T. M. I. (2023). Recent progress in electrolyser control technologies for hydrogen energy production: A patent landscape analysis and technology updates. *Journal of Energy Storage*, 72, 108773. <https://doi.org/10.1016/J.EST.2023.108773>
- Ali, A., Shaukat, H., Bibi, S., Altabey, W. A., Noori, M., & Kouritem, S. A. (2023). Recent progress in energy harvesting systems for wearable technology. *Energy Strategy Reviews*, 49, 101124. <https://doi.org/10.1016/J.ESR.2023.101124>
- Ayu, D. K., Susilaningrum, D., & Suhartono, S. (2016). Pemodelan Produksi Minyak dan Gas Bumi di PT. "Z" Menggunakan Metode ARIMA, FFNN, dan Hybrid ARIMA-FFNN. *Jurnal Sains Dan Seni ITS*, 5(2), 2337–3520. <https://doi.org/10.12962/J23373520.V5I2.17189>
- Dong, J., Song, B., He, F., Xu, Y., Wang, Q., Li, W., & Zhang, P. (2023). Research on a Hybrid Intelligent Method for Natural Gas Energy Metering. *Sensors (Basel, Switzerland)*, 23(14). <https://doi.org/10.3390/S23146528>

- Fan, D., Sun, H., Yao, J., Zhang, K., Yan, X., & Sun, Z. (2021). Well production forecasting based on ARIMA-LSTM model considering manual operations. *Energy*, 220, 119708. <https://doi.org/10.1016/J.ENERGY.2020.119708>
- Fry, M., Brannstrom, C., & Sakinejad, M. (2017). Suburbanization and shale gas wells: Patterns, planning perspectives, and reverse setback policies. *Landscape and Urban Planning*, 168, 9–21. <https://doi.org/10.1016/J.LANDURBPLAN.2017.08.005>
- Glushchenko, A., Petrov, V., & Lastochkin, K. (2021). Backpropagation method modification using Taylor series to improve accuracy of offline neural network training. *Procedia Computer Science*, 186, 202–209. <https://doi.org/10.1016/J.PROCS.2021.04.139>
- Goh, A. T. C. (1995). Back-propagation neural networks for modeling complex systems. *Artificial Intelligence in Engineering*, 9(3), 143–151. [https://doi.org/10.1016/0954-1810\(94\)00011-S](https://doi.org/10.1016/0954-1810(94)00011-S)
- Gonzalez, D. J. X., Sherris, A. R., Yang, W., Stevenson, D. K., Padula, A. M., Baiocchi, M., Burke, M., Cullen, M. R., & Shaw, G. M. (2020). Oil and gas production and spontaneous preterm birth in the San Joaquin Valley, CA: A case-control study. *Environmental Epidemiology*, 4(4). <https://doi.org/10.1097/EE9.0000000000000099>
- Hecht-Nielsen, R. (1992). Theory of the Backpropagation Neural Network. *Neural Networks for Perception*, 65–93. <https://doi.org/10.1016/B978-0-12-741252-8.50010-8>
- Hennings, P., Allwardt, P., Paul, P., Zahm, C., Reid, R., Alley, H., Kirschner, R., Lee, B., & Hough, E. (2012). Relationship between fractures, fault zones, stress, and reservoir productivity in the Suban gas field, Sumatra, Indonesia. *AAPG Bulletin*, 96(4), 753–772. <https://doi.org/10.1306/08161109084>
- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., & Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 388–395. <https://doi.org/10.30865/jurikom.v9i1.3846>
- Liu, H., Liu, Y., Wang, C., Song, Y., Jiang, W., Li, C., Zhang, S., & Hong, B. (2023a). Natural Gas Demand Forecasting Model Based on LASSO and Polynomial Models and Its Application: A Case Study of China. *Energies*, 16(11). <https://doi.org/10.3390/EN16114268>
- Liu, H., Liu, Y., Wang, C., Song, Y., Jiang, W., Li, C., Zhang, S., & Hong, B. (2023b). Natural Gas Demand Forecasting Model Based on LASSO and Polynomial Models and Its Application: A Case Study of China. *Energies*, 16(11). <https://doi.org/10.3390/EN16114268>
- Liu, X., Tang, H., Zhang, D., Geng, S., Wu, G., Li, C., & Liu, S. (2023). A prediction model for new well deliverability in an underground gas storage facility using production data. *Journal of Energy Storage*, 60, 106649. <https://doi.org/10.1016/J.EST.2023.106649>
- Nagar, R., Srivastava, S., Hudson, S. L., Amaya, S. L., Tanna, A., Sharma, M., Achayalingam, R., Sonkaria, S., Khare, V., & Srinivasan, S. S. (2023). Recent developments in state-of-the-art hydrogen energy technologies – Review of hydrogen storage materials. *Solar Compass*, 5, 100033. <https://doi.org/10.1016/J.SOLCOM.2023.100033>
- Nourislam, A., Jondri, J., & Saadah, S. (2014). Analisis dan Implementasi Jaringan Syaraf Tiruan – Propagasi Balik Dalam Memprediksi Produksi dan Konsumsi Minyak Bumi, Gas Bumi, dan Batu Bara di Indonesia. *EProceedings of Engineering*, 1(1), 558–564.
- Purnawan, H., Putra, R. A. P., Fauzi, R., Setiawan, A. D., Jaenul, A., Al-Hakim, R. R., Nugroho, H. S., & Kuntjoro, Y. D. (2024). Using Backpropagation Neural Network for Polyvinylchloride Ceiling Price Modeling. *Informatich: Jurnal Ilmiah Informatika Dan Komputer*, 1(1), 26–30.
- Puspitaningrum, D. (2006). *Pengantar Jaringan Saraf Tiruan*. Andi.
- Sutama, C., & Inayah, F. (2013). Expanding Cement Application for High Rate Gas Wells in South Sumatra. *Society of Petroleum Engineers - SPE Asia Pacific Oil and Gas Conference and Exhibition, APOGCE 2013: Maximising the Mature, Elevating the Young*, 1, 368–376. <https://doi.org/10.2118/165792-MS>

- Szoplik, J., & Muchel, P. (2023). Using an artificial neural network model for natural gas compositions forecasting. *Energy*, 263, 126001. <https://doi.org/10.1016/J.ENERGY.2022.126001>
- Vlachas, P. R., Pathak, J., Hunt, B. R., Sapsis, T. P., Girvan, M., Ott, E., & Koumoutsakos, P. (2020). Backpropagation algorithms and Reservoir Computing in Recurrent Neural Networks for the forecasting of complex spatiotemporal dynamics. *Neural Networks*, 126, 191–217. <https://doi.org/10.1016/J.NEUNET.2020.02.016>
- Wong, F. S. (1991). Time series forecasting using backpropagation neural networks. *Neurocomputing*, 2(4), 147–159. [https://doi.org/10.1016/0925-2312\(91\)90045-D](https://doi.org/10.1016/0925-2312(91)90045-D)
- Wythoff, B. J. (1993). Backpropagation neural networks: A tutorial. *Chemometrics and Intelligent Laboratory Systems*, 18(2), 115–155. [https://doi.org/10.1016/0169-7439\(93\)80052-J](https://doi.org/10.1016/0169-7439(93)80052-J)
- Zhang, M., Mu, L., Li, C., Zheng, K., Duan, L., Wang, G., Zuo, S., & Li, D. (2017). Mature Condensated Gas Field Development Strategy: An Integration of Geophysics, Geology and Log for the South Sumatra Basin, Indonesia. *SPE Reservoir Characterisation and Simulation Conference and Exhibition, RCSC 2017*, 513–523. <https://doi.org/10.2118/186060-MS>