

SISTEM PERINGATAN DINI BANJIR BERBASIS MACHINE LEARNING: STUDI LITERATUR

¹Agustina Rachmawardani[✉], ²Sastra K. Wijaya, ³Ardhasena Shopaheluwakan

¹Prodi Instrumentasi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Jakarta, Indonesia

²Departemen Fisika, FMIPA, Universitas Indonesia

³Badan Meteorologi Klimatologi dan Geofisika, Indonesia

Email: agustina.rahmawardani@stmkg.ac.id

DOI: <https://doi.org/10.46880/jmika.Vol6No2.pp188-198>

ABSTRACT

Indonesia is a disaster-prone country and 76% is a hydrometeorological disaster (floods, landslides, tropical cyclones and droughts). Floods that occurred in Jakarta had a negative impact on the community so that it would have an impact on economic losses that made it difficult for communities around areas that were frequently affected by floods to develop more advanced and productively. Therefore, the inhibition of increasing welfare caused by floods that are not immediately handled can increase the number of people's poverty because they always have to spend both on house repairs, health and other things caused by floods. In addition, public facilities and various kinds of infrastructure were damaged. The environment is also negatively affected when floods occur. Clean water is difficult to obtain so it causes many diseases. Floods also cause animals to be killed, thereby disrupting the natural balance of the ecosystem. The existence of flood prediction research will reduce the risk and damage caused by flood disasters and can provide advice and considerations in policy making. Flood early warning system is one of the solutions offered in dealing with flood disasters. Providing actual and real time information, this early warning system is expected to reduce economic losses to fatalities. In an effort to create a resilient city, ESCAP (2008) puts an early warning system in place as an effort to prepare before a disaster occurs and to mitigate floods.

Keyword: *Early Warning, Flood, Machine Learning, Ensemble.*

ABSTRAK

Indonesia merupakan negara rawan bencana dan 76% merupakan bencana hidrometeorologi (banjir, longsor, siklon tropis dan kekeringan). Banjir yang terjadi di Jakarta membawa dampak negatif bagi masyarakat sehingga akan membawa dampak kerugian ekonomi yang membuat masyarakat sekitar wilayah yang sering terkena banjir akan susah berkembang lebih maju dan produktif. Oleh sebab itu penghambatan peningkatan kesejahteraan yang diakibatkan karena banjir yang tidak segera ditangani bisa membuat meningkatnya jumlah kemiskinan, warga karena harus mengeluarkan biaya baik untuk perbaikan rumah, kesehatan dan lain lain. Selain itu fasilitas-fasilitas umum dan berbagai macam infrastruktur banyak mengalami kerusakan. lingkungan juga terkena dampak negatif ketika terjadi banjir. Air bersih sulit untuk didapatkan sehingga banyak menimbulkan penyakit. Banjir juga menyebabkan hewan-hewan terbunuh sehingga mengganggu keseimbangan alami ekosistem. Dengan adanya penelitian prediksi banjir akan mengurangi resiko dan kerusakan yang diakibatkan oleh bencana banjir serta dapat memberikan saran dan pertimbangan dalam pengambilan kebijakan. Sistem peringatan dini banjir menjadi salah satu solusi yang ditawarkan dalam menghadapi bencana banjir. Memberikan informasi aktual dan real time, sistem peringatan dini ini diharapkan dapat mengurangi kerugian ekonomi hingga korban jiwa. Dalam upaya mewujudkan kota tangguh, ESCAP (2008) menempatkan sistem peringatan dini sebagai upaya kesiapsiagaan (preparedness) sebelum terjadi bencana dan mitigasi banjir.

Kata Kunci: *Peringatan Dini, Banjir, Machine Learning, Ensemble.*

PENDAHULUAN

Banjir merupakan bencana alam yang paling sering terjadi di Asia. Salah satu Negara Asia dengan dampak banjir tertinggi adalah Indonesia khususnya di ibukota Negara yaitu Jakarta. Jakarta sebagai ibukota

Negara sudah beberapa kali mengalami banjir besar pada abad ke dua puluh satu ini yaitu pada tahun 2002, 2007, 2013, 2015 dan 2020. Banjir tahun 2007 dianggap sebagai bencana nasional yang mengakibatkan kerugian sebesar US \$ 565 juta. Sektor

perumahan adalah yang paling besar terkena imbasnya sekitar 74 % dari total kerugian. (Bappenas, 2007). Hujan deras yang mengguyur Jakarta dan kota-kota besar sekitarnya pada tanggal 17-19 Januari 2013 menyebabkan banjir besar dan menggenangi 98.000 perumahan sehingga membuat 40.000 orang harus mengungsi dan korban jiwa sebanyak 20 orang. Banjir tersebut menyebabkan kerusakan total yang diperkirakan mencapai US \$ 775 juta. (Badan Penanggulangan Bencana Daerah (BPBD), 2013). Peristiwa ini menunjukkan banjir merupakan masalah serius di Jakarta.

Manajemen banjir konvensional bergantung pada pemantauan curah hujan dan debit sungai ground based. Beberapa negara tropis mempunyai resiko banjir yang cukup tinggi dan juga terdapat bagian dari daratan tidak tercover oleh jaringan sensor banjir sedangkan data spasial penginderaan jauh menyediakan manajemen data tepat waktu dan biaya rendah sehingga penggabungan antara data daratan dan data remote sensing bisa menghasilkan prediksi banjir yang bagus dan akurat. Banyak aspek manajemen banjir terbantu dengan kemajuan teknologi di bidang remote sensing ini. Deteksi banjir yang lebih tepat dan real time, lead time pada sistem early warning banjir dan input yang akurat dari model hidrologi saat ini dikarenakan teknologi remote sensing yang digunakan.

Kejadian banjir dapat dimodelkan secara fisis dengan menggunakan persamaan matematis yang kompleks. Machine Learning sebagai sistem perancangan dan pengembangan algoritma yang dapat melakukan prediksi kejadian banjir dengan menggunakan data-data historis. Sistem pembelajar (machine learning) dapat memanfaatkan data yang ada menghasilkan nilai probabilitas yang mendasarinya sehingga berkontribusi besar dalam sistem prediksi yang memberikan kinerja yang lebih baik dan solusi yang hemat biaya. Prediksi yang tepat dan akurat dapat memberikan kontribusi pada strategi manajemen sumber daya air, saran dan analisis kebijakan dan pemodelan evakuasi lebih lanjut. (Xie, Ozbay, Zhu, & Yang, 2017).


TINJAUAN PUSTAKA

Metode Machine Learning pada Prediksi Banjir

Dengan menggunakan machine learning dapat merumuskan secara numerik banjir nonlinier, berdasarkan data historis tanpa memerlukan proses fisis yang mendasari. Model prediksi berdasarkan data menggunakan machine learning cukup menjanjikan karena dapat berkembang lebih cepat dengan input minimal. Machine learning merupakan bagian dari


artificial intelegent yang digunakan untuk menginduksi keteraturan dan pola, memberikan implementasi yang lebih mudah dengan biaya komputasi yang rendah, serta pelatihan, validasi, pengujian, dan evaluasi yang cepat, dengan kinerja tinggi dibandingkan dengan model fisik. (Mekanik, Imteaz, Gato-Trinidad, & Elmahdi, 2013). Sumber data yang digunakan dalam prediksi algoritma machine learning menggunakan data-data historis banjir seperti data curah hujan dan water level yang didapat dari ground rain gauge atau bisa juga data remote sensing seperti satelit, system multisensory dan radar. Bahkan remote sensing merupakan salah satu instrument yang cukup menarik untuk mengambil data image secara real time. Resolusi yang tinggi dari pengamatan satelit cuaca sangat sesuai dan seringkali memberikan dataset yang lebih handal dibandingkan dengan alat pengukur hujan. Dengan demikian, membangun model prediksi berdasarkan kumpulan data curah hujan dan satelit akan memberikan akurasi yang lebih tinggi secara umum. (Bhatti, Rientjes, Haile, Habib, & Verhoef, 2016).

Setelah data-data historis yang berkaitan dengan banjir tersebut didapatkan maka langkah selanjutnya adalah melakukan training, validasi dan pengujian. Gambar 1 dibawah ini menunjukkan flowchart pemodelan machine learning.




Gambar 1. Flowchart Pemodelan machine Learning

Pemodelan machine learning yang paling banyak digunakan untuk prediksi banjir dapat dilihat pada gambar 2 di bawah ini sedangkan gambar 3 menunjukkan aplikasi Machine Learning dengan metode single dan hybrid untuk prediksi banjir pada satu dekade terakhir.



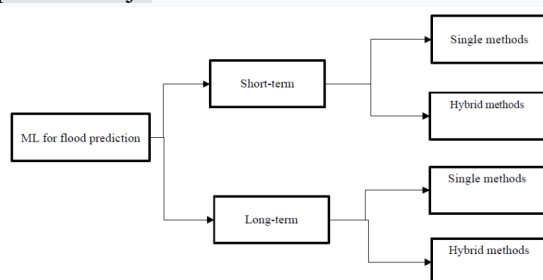
Gambar 2. Metode Machine Learning untuk Prediksi Banjir



Gambar 3. Penggunaan ML metode single vs Hybrid untuk prediksi banjir

Dari gambar 2.2 dapat diketahui bahwa ANN adalah metode machine learning yang sering digunakan, kemudian SVM dan SVR. Selain itu DT, RF dan CART juga cukup populer untuk digunakan. Metode machine learning dapat dikategorikan menjadi metode single atau hybrid. Metode machine learning hybrid antara lain menggunakan algoritma ANFIS, WNN dan juga EPS untuk mendapatkan hasil prediksi yang lebih baik (Tehrany, Pradhan, & Jebur, 2014).

Metode machine learning dapat dikerjakan dengan dua tipe algoritma yaitu metode single algoritma dan hybrid algoritma. Gambar 4 mewakili metode machine learning yang digunakan untuk prediksi banjir



Gambar 4. Metode Machine Learning untuk Prediksi Banjir

Short Term Flood Prediction dengan Menggunakan single ML

Short term flood prediction merupakan hal yang penting dalam penelitian banjir khususnya daerah perkotaan sebagai peringatan dini daerah pemukiman penduduk untuk mengurangi resiko.

Pada penelitiannya (Valipour, Banihabib, & Behbahani, 2012) mengembangkan pemodelan ANN dengan lead time perjam. Dataset yang digunakan terdiri dari parameter meteorologi dan hidrodinamik dari tiga topan. Tahap testing pada model ANN menunjukkan hasil yang bagus untuk lead 5 jam. Pada penelitian Danso Amoako (Danso-Amoako, Scholz, Kalimeris, Yang, & Shao, 2012) menggunakan algoritma ANN untuk prediksi banjir. Dari hasil penelitian didapatkan nilai R^2 adalah 0.70. Hal tersebut menunjukkan bahwa ANN sangat sesuai digunakan sebagai prediksi banjir. Hasil dari penelitian (Saghafian, Haghnegahdar, & Dehghani, 2017) juga menunjukkan tingkat akurasi yang hampir sama. Panda, Pramanik dan bala (Panda, Pramanik, & Bala, 2010) membandingkan antara pemodelan ANN dengan algoritma FFAN dan hasilnya dibandingkan dengan model MIKE 11 untuk prediksi water level jangka pendek. Dataset terdiri atas debit air dan water level tiap jam Antara tahun 2006 – 2009. Data tahun 2006 digunakan untuk menghitung RMSE (Root Mean Square Error). Hasil penelitian menunjukkan bahwa performa FFANN lebih cepat dan lebih akurat. Dari penelitian yang dilakukan menunjukkan bahwa ANN lebih unggul dibandingkan dengan model satu dimensi MIKE 11.

Kourgialas, Dokou, and Karatzas (Kourgialas, Dokou, & Karatzas, 2015) membuat sistem pemodelan prediksi banjir berbasis ANN dengan input untuk aliran ekstrim untuk 3 jam, 12 jam dan 19 jam kedepan. Mereka menganalisa data tiap jam selama lima tahun untuk menunjukkan efektivitas ANN dalam pemodelan kejadian banjir ekstrim. Hasil penelitian menunjukkan bahwa ANN sangat efektif dibanding model konvensional hidrologi. Lohani, Goel, and Bhatia (Lohani, Goel, & Bhatia, 2014) meningkatkan prakiraan curah hujan secara real time – banjir limpasan dan hasilnya dibandingkan dengan model T-S fuzzy dan model T-S (TSC-T-S) fuzzy berbasis clustering substraktif. Dari hasil penelitian menunjukkan bahwa model fuzzy merupakan prediksi yang lebih akurat dengan lead time lebih lama. Data curah hujan tiap jam dari tahun 1989 – 1995 dan juga curah hujan selama monsoon juga digunakan. Pereira Filho and dos Santos (Pereira Filho & Dos Santos, 2006) membandingkan model AR dengan ANN untuk simulasi prediksi

streamflow dan level air. Dataset yang digunakan adalah data banjir, radar-curah hujan, dan data rain gauge (streamflow) antara tahun 1991 – 1995. AR dan ANN digunakan dalam prediksi jangka pendek di daerah perkotaan dengan menggunakan data aliran sungai dan data cuaca. Dari hasil penelitian menunjukkan bahwa performa ANN lebih bagus dan lebih akurat dibanding model AR.

Ahmad and Simonovic (Ahmad & Simonovic, 2005) menggunakan BPNN untuk prediksi peak flow (aliran puncak) dengan menggunakan parameter meteorologi. Dataset yang digunakan dari stasiun cuaca dari tahun 1958 – 1997. BPNN terbukti menjadi pemodelan yang akurat untuk diterapkan pada lokasi sungai yang lain. Sebagai pengembangan dalam penelitian simulasi aliran sungai harian menggunakan BPNN. Dalam penelitiannya (Ju et al., 2009) menggunakan propagasi mundur mendapatkan hasil yang lebih bagus. Data lokal penguapan dan alat pengukur curah hujan selama 6 tahun digunakan untuk prediksi banjir time series aliran sungai. Dataset satu dekade dari 1988 digunakan untuk pelatihan dan set data lima tahun berikutnya digunakan untuk pengujian. Model BPNN menghasilkan data cukup akurat hanya kurang efisien dalam penggunaan data mentah prediksi deret waktu aliran sungai. Referensi (Sahoo, Ray, & De Carlo, 2006) menunjukkan pemodelan BPNN untuk prediksi banjir bandang dengan data terukur. Data set terdiri atas data kualitas air dengan frekwensi 5 menit dan data curah hujan dengan frekwensi 20 menit dari dua stasiun pengukur hujan. Dalam penelitian tersebut menunjukkan bahwa ANN sebagai machine learning yang sederhana dimana pembelajaran yang kompleks perlu diketahui oleh user. Model prediksi ANN juga menunjukkan hasil yang bagus untuk data set noisy. (Ghose, 2018) memprediksi daily runoff dengan menggunakan model prediksi BPNN dengan menggunakan data harian water level selama 2 tahun dari tahun 2013 – 2015 . Dari hasil penelitian prediksi banjir tersebut didapat efisiensi 96.4 % dan R^2 0.94.

Pan, Cheng, and Cai (Cheng, Cai, & Pan, 2009) membandingkan performansi ELM dan SVM untuk prediksi jangka pendek aliran sungai. Kedua metode tersebut mempunyai akurasi yang hampir sama. Referensi (Jingyi & Hall, 2004) juga membandingkan Antara Fuzzy c-means , ANN dan MLP dengan menggunakan dataset yang umum untuk menghasilkan nilai yang akurat dan efisien. Metode MLP dan ANN merupakan metode yang terbaik. Chang, Chen, Lu, Huang, and Chang (Chang, Chen, Lu, Huang, & Chang, 2014) and Reference (Shen & Chang, 2013) memodelkan prakiraan banjir perkotaan dengan

menggunakan BPNN dan nonlinear autoregressive network with exogenous input (NARX) untuk prakiraan per jam. Dari hasil penelitian menunjukkan bahwa NARX bekerja lebih bagus pada prediksi jangka pendek dibanding BPNN. Algoritma NARX menghasilkan nilai R^2 0.7. Hal tersebut menunjukkan bahwa algoritma NARX efektif digunakan untuk prediksi banjir perkotaan. (Valipour et al., 2012) menunjukkan akurasi pemodelan ANN dapat bertambah dengan integrasi model autoregressive (AR).

(Aichouri et al., 2015) mengimplementasikan model MLP untuk prediksi banjir dan hasilnya dibandingkan dengan model tradisional MLR. Dataset yang digunakan adalah data curah hujan – limpasan harian dari tahun 1986 – 2003. Hasil dari perbandingan tersebut menunjukkan performa MLP lebih baik untuk curah hujan sungai- limpasan. Referensi (Leahy, Kiely, & Corcoran, 2008) mendesain pemodelan ANN dengan algoritma back propogation yang optimal untuk level sungai. Dari hasil penelitian pemodelan ANN mempunyai kualitas prediksi lebih bagus dan lebih akurat untuk pemodelan prediksi banjir jangka pendek dibanding metode statistic konvensional. Input data terdiri dari level sungai dan rata-rata tekanan level air laut (SLP) periode 2001 – 2002.

Referensi (Yu, Yang, Chen, Kuo, & Tseng, 2017) tentang penelitian prediksi banjir real time menggunakan dataset curah hujan yang diambil dari radar. Pemodelan RF dan SVM dikembangkan dalam penelitian ini dan hasil keduanya kemudian dibandingkan. Dari hasil perbandingan tersebut diketahui bahwa SVM lebih efektif pada prediksi banjir secara real time.

Short-Term Flood Prediction dengan Menggunakan Metode Hybrid ML

Untuk memperbaiki kualitas prediksi yaitu akurasi, generalisasi, ketidakpastian, lead time yang lebih lama, kecepatan, maka digunakan pemodelan hybrid. ML (Chang & Chang, 2006) membangun sistem prediksi ketinggian air berbasis ANFIS selama 1 – 3 jam sebelum banjir. ANFIS berhasil memberikan prediksi ketinggian air yang akurat. Ketinggian air perjam dengan dataset tahun 1971 – 2001 dari 5 peralatan. Dari hasil penelitian dapat disimpulkan bahwa pemodelan ANFIS efisien digunakan dengan dataset yang besar melalui pembelajaran yang cepat dan sistem prediksi yang handal. Perbandingan lebih lanjut menunjukkan bahwa model hibrida ANFIS yang disetel oleh SVR memberikan akurasi prediksi yang bagus dan komputasi hemat biaya dan baik untuk

prediksi banjir nonlinier dan real-time. Sebagai tambahan pemodelan dengan interaksi manusia atau reservoir outflow dapat menghasilkan performansi yang lebih bagus. (Rezaeianzadeh, Tabari, Arabi Yazdi, Isik, & Kalin, 2014) melakukan penelitian sistem prediksi untuk prediksi aliran harian menggunakan ANN, ANFIS, MLR dan MNLR. Performansi model dapat dihitung dengan RMSE dan R^2 . Dataset meliputi data curah hujan dari berbagai stasiun meteorologi. Dari hasil evaluasi menunjukkan pemodelan MNLR dengan RMSE rendah mempunyai performansi lebih bagus dari model ANFIS, MLR, and ANN. MNLR disarankan sebagai model berbiaya rendah dan efisien untuk prediksi aliran harian

(Young, Liu, & Wu, 2017) mengembangkan pemodelan hybrid dengan integrasi HEC – HMS dengan SVM dan ANN untuk pemodelan curah hujan – limpasan selama badai topan. Pemodelan hybrid HEC- HMS – SVR dan HEC-HMS-ANN memiliki kemampuan prediksi tiap jam. Dari hasil penelitian menunjukkan pemodelan SVR memiliki kemampuan generalisasi dan akurasi yang jauh lebih baik dalam prediksi debit limpasan dari ANN model. Dapat disimpulkan prediksi HEC – HMS dapat diperbaiki melalui hibridisasi machine learning.

(Dodangeh et al., 2020) melakukan penelitian pemodelan hybrid berbasis meta- optimasi dari SVR dan Group Method of data Handling (GMDH) menggunakan algoritma meta-heuristic yang berbeda yaitu Genetic algoritma (GA) dan harmony search (HS). Dataset yang digunakan adalah 132 lokasi banjir di wilayah studi, 92 titik (70%) digunakan bersama dengan data geospasial untuk pemodelan kerentanan banjir, dan 40 titik sisanya (30%) digunakan untuk memvalidasi model. Model kerentanan banjir awal dibangun berdasarkan model SVR dan GMDH. Parameter model dioptimalkan menggunakan GA dan HS untuk mereproduksi peta kerentanan banjir. Akurasi prediksi dari peta yang dihasilkan dievaluasi dalam berbagai ukuran statistik, yaitu, mean square error (MSE), root mean square error (RMSE), kurva karakteristik operasi penerima (ROC), dan area di bawah kurva ROC (AUC). Hasil penelitian menunjukkan bahwa model SVR memiliki kinerja yang lebih unggul dibandingkan dengan model. Baik GA dan HS sangat meningkatkan kinerja SVR dan GMDH, dengan model SVR-GA berkinerja terbaik (AUC = 0,75, RMSE = 0,29, MSE = 0,08) diikuti oleh model SVR-HS (AUC = 0,75, RMSE = 0,33, MSE = 0,11). Dari penelitian disimpulkan bahwa model hibrida efisien untuk prediksi kerentanan banjir spasial.

(Nanda, Sahoo, Beria, & Chatterjee, 2016) melakukan prediksi harian curah hujan dengan dataset dari peralatan pengukur curah hujan dari 2000 – 2010. Pemodelan yang digunakan adalah NARX berbasis wavelet (WNARX). Kinerja prediksi selanjutnya dibandingkan dengan model JST, WANN, ARMAX, dan NARX, dimana pemodelan WNARX mempunyai nilai akurasi yang lebih tinggi dibanding model lain. (French, Mawdsley, Fujiyama, & Achuthan, 2017) melakukan penelitian model hibrida JST dan model hidrodinamik untuk prediksi akurat jangka pendek gelombang air badai ekstrim. Model ANN-hidrodinamik menghasilkan luasan banjir yang realistis dan nilai akurasi yang tinggi. Melalui EPS model, penelitian (Doycheva, Horn, Koch, Schumann, & König, 2017) bertujuan membatasi ketidakpastian dalam simulasi limpasan dan prediksi banjir. Classifier ensembles meliputi MLP, SVM dan RF. Ensemble MLP merupakan pendekatan baru pada prediksi banjir. EPS yang digunakan menyajikan sejumlah model terintegrasi dan simulasi berjalan. Validasi model berhasil dilakukan dengan menggunakan dataset dari berbagai alat pengukur hujan dari data curah hujan selama musim badai 2013-2014. Dengan menggunakan pemodelan EPS mengurangi ketidakpastian pada prediksi dan sebagai sistem prediksi yang handal dalam memprediksi durasi banjir yang merusak.

Analisis Kinerja

Untuk mengevaluasi prediksi yang handal, akurat, terpercaya maka ketepatan waktu merupakan kriteria dasar. Selain itu performansi dari model prediksi dievaluasi melalui root-mean-square error (RMSE), mean error (ME), mean squared error (MSE), Nash coefficients (E), dan R^2 , dan disebut juga sebagai correlation coefficient (CC). Nilai R^2 atau koefisien korelasi dan RMSE dapat didefinisikan sebagai berikut:


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{[\sum_{i=1}^N (x_i - \bar{x})^2][\sum_{i=1}^N (y_i - \bar{y})^2]}}$$


di mana x_i dan y_i adalah nilai yang diamati dan diprediksi serta nilai ke- i , dimana x_{obs} didefinisikan variabel yang diamati dan nilai prediksi model x untuk tahun i , umumnya $R^2 > 0.8$ dianggap sebagai prediksi

yang dapat diterima. Secara keseluruhan, model peramalan banjir dilaporkan akurat jika nilai RMSE mendekati 0 dan nilai R^2 mendekati 1.

Perbandingan metode ML tunggal dan hibrida untuk prediksi banjir jangka pendek menggunakan R^2 dan RMSE masing-masing disajikan pada Gambar 5 dan 6.



Gambar 5. Perbandingan analisa metode short term single ML menggunakan R^2 dan root mean square error (RMSE)



Gambar 6. Perbandingan analisa metode short term hybrid ML menggunakan R^2 dan root mean square error (RMSE)

Secara umum, ANN merupakan prediksi yang cukup bagus untuk jangka pendek dengan dataset yang besar. BPNN dan Network function sulit diimplementasikan oleh user tapi bagaimanapun pemodelan tersebut cukup akurat, efisien dan cepat dengan noisy datasets. Pemodelan NARX mempunyai performansi cukup bagus dibanding BPNN. Bahkan akurasi dapat ditingkatkan melalui integrasi dengan Autoregression (AR). MLP dan DT menghasilkan prediksi yang cukup akurat juga dikombinasikan dengan ANN. Diantara Decision Tree (DT), pemodelan ADT menghasilkan prediksi yang lebih akurat dan cepat dalam menentukan banjir. Meskipun tidak sepopuler ANN Random Forest (RF) dan M5 model tree dilaporkan cukup efisien dan robust. SVM juga merupakan pilihan yang sesuai yang digunakan untuk

prediksi banjir, dan cukup efektif untuk menghasilkan prediksi banjir secara real time.

Secara keseluruhan pemodelan single prediction cukup akurat untuk prediksi jangka pendek. Tetapi untuk prediksi yang lebih lama dari 2 jam hybrid model seperti ANFIS dan WNN mempunyai performansi yang cukup bagus. Perbandingan performansi pemodelan ANFIS dengan BPNN dan AR dengan koefisien korelasi 0.8 menunjukkan bahwa ANFIS secara umum cukup bagus untuk pemodelan prediksi banjir jangka pendek dengan dataset tinggi air, curah hujan – limpasan dan aliran sungai. Lebih lanjut Model hybrid ANFIS dituning dengan SVR menghasilkan akurasi prediksi yang bagus dan hemat biaya untuk prediksi non linier dan real time. Untuk aliran harian MNLr mempunyai performansi yang cukup bagus disbanding ANN, ANFIS dan MNLr model. Pada beberapa kasus dengan data hidrometeorologi CART juga cukup bagus dibanding pemodelan ANN, ANFIS dan MLR, T-S fuzzy juga merupakan pilihan yang bagus. Di sisi lain, metode ansambel tidak hanya meningkatkan ketepatan prediksi, tetapi juga berkontribusi untuk membatasi ketidakpastian dalam pemodelan. Di antara metode EPS, ensemble JST, MLP, SVM, dan RF menunjukkan hasil yang menjanjikan.

Long -Term Flood Prediction dengan menggunakan metode single ML

Bab ini membahas tentang summary beberapa penelitian dengan menggunakan metode single ML dalam prediksi banjir jangka panjang. Untuk prediksi banjir musiman, (Elsafi, 2014) melakukan penelitian tentang JST dan membandingkan hasilnya. Data ketinggian air dari stasiun yang berbeda dari tahun 1970–1985 dipilih untuk pelatihan, dan data dari tahun 1986–1987 digunakan untuk verifikasi. ANN bekerja dengan baik khususnya untuk data yang tidak lengkap dan dapat melakukan prediksi yang akurat.

Hampir sama dengan penelitian diatas, (Deo & Şahin, 2015) juga menggunakan ANN juga dalam mengembangkan model prediksi untuk curah hujan. Sebagai input digunakan historical dataset dari tahun 1900 – 2001 dari berbagai stasiun dan model ANN diterapkan diberbagai stasiun tersebut untuk mengavaluasi performansi yang didapat. Dari hasil penelitian didapat bahwa pemodelan ANN merupakan prediksi yang akurat untuk prediksi evaporasi dan presipitasi jangka panjang.

Penelitian (Gazendam, Gharabaghi, Ackerman, & Whiteley, 2016) menggunakan model ANN untuk prediksi banjir jangka panjang. Dataset berasal lebih

dari seratus (100) lokasi aliran banjir. Dari hasil penelitian disimpulkan bahwa pemodelan ANN dibanding dengan Hilsenhoff's biotic index (HBI) secara signifikan meningkatkan kemampuan prediksi banjir dengan data geomorphic. ANN pada penelitian ini terbukti memiliki kemampuan dalam prediksi banjir.

Penelitian (Shamim, Hassan, Ahmad, & Zeeshan, 2016) bertujuan untuk analisa banjir nonlinier dengan pemodelan BPNN dan Local Linier Regression (LLR) untuk prediksi banjir jangka panjang. Dataset yang digunakan selama dua dekade terdiri atas data curah hujan, outflow, inflow, evaporasi dan water level sejak tahun 1988. Hasil penelitian menunjukkan bahwa LLR mempunyai prediksi yang lebih bagus dari pada model Broyden Fletcher Goldfarb Shanno neural network (BFGSNN) yang ditunjukkan dengan R² mendekati satu dan nilai RMSE yang rendah. Namun BPNN menggungguli metode yang lain dengan hasil yang relatif baik.

Referensi (Cunningham, Griffioen, White, & Nally, 2018) menggunakan Regression Tree (RT) untuk memodelkan hutan dataran banjir. Pemodelan menghasilkan prediksi yang bagus untuk data dari 2009 – 2012 pada lima puluh (50) site. Kondisi hutan dataran banjir data dipetakan secara akurat menggunakan input data kombinasi survei lapangan kuantitatif, citra satelit, hybrid machine learning dan future validasi.

Long -Term Flood Prediction dengan menggunakan metode ML Hybrid

Review Prediksi Banjir jangka panjang menggunakan metode hybrid ditunjukkan pada tabel 1

Tabel 1. Prediksi Banjir Jangka Panjang

Modelling technique	Reference	Flood Resource Variable	Prediction Type	Region
Autoregressive ANN vs. ARMA vs. ARIMA	Valipour et al., 2013	River inflow	Bulanan dan tahunan	Iran
Hybrid WNN vs. M5 model tree	Prasad et al., 2017	Streamflow water level	Bulanan	Australia
WNN vs. ANN	Ghamariadyan & Imteaz, 2021	Rainfall	bulanan	Australia
Surrogate modeling- ML vs. ANN- Kriging model vs. ANN-PCA	Bass & Bedient, 2018	Rainfall - runoff	tahunan	USA

EEMD-ANN vs. SVM vs. ANFIS	Tan et al., 2018	Runoff forecast	Bulanan	China
WNN vs. ANN vs. WLGP	Ravansalar et al., 2017	Streamflow	Bulanan	Iran

Valipour, Banihabib, and Behbahani (Valipour, Banihabib, & Behbahani, 2013) menggunakan metode hybrid autoregressive ANN diintegrasikan dengan fungsi aktivasi sigmoid dan radial. Metode hybrid ARMA dan ARIMA yang digunakan mempunyai hasil yang lebih baik dari metode statistik konvensional yaitu dengan nilai RMSE yang lebih rendah. Dari hasil penelitian didapatkan bahwa ARIMA cocok untuk prediksi inflow bulanan dan tahunan, sedangkan model ANN autoregresif dinamis dengan fungsi aktivitas sigmoid dapat digunakan untuk lead time yang lebih lama.

Penelitian (Ghamariadyan & Imteaz, 2021) bertujuan untuk mengembangkan model prediksi curah hujan jangka menengah curah hujan bulanan 1, 3, 6, dan 12 bulan menggunakan hybrid wavelet artificial neural networks (WANN) di Queensland, Australia. Untuk menilai kinerja model, dataset terdiri atas tujuh set input data histori curah hujan, anomali iklim atau kombinasi curah hujan dengan anomali iklim yang berbeda sebagai variabel independen yang ditentukan. Data dari tahun 1908–1999 dan 2000–2016 dari 10 stasiun cuaca digunakan untuk pelatihan dan verifikasi model. Hasil penelitian saat ini menunjukkan bahwa kinerja WANN lebih akurat daripada prakiraan ANN, ARIMA, MLR, dan ACCESS-S.

(Prasad, Deo, Li, & Maraseni, 2017) melakukan penelitian model hybrid lain yaitu dengan integrasi WNN dan Iterative Input Selection (IIS). Model hibrida disebut IIS – W-ANN, dan dibandingkan dengan model tree M5. Dataset yang digunakan adalah pengukuran ketinggian air aliran sungai selama 40 tahun. Model hybrid IIS-W-ANN mempunyai performansi lebih baik dari model tree M5. Studi ini menganjurkan bahwa metode baru IIS-W-ANN dianggap sebagai model prakiraan banjir yang sangat baik.

(Bass & Bedient, 2018) mengusulkan model hibrida pengganti – machine learning untuk prediksi banjir jangka panjang yang cocok yang sesuai dengan siklon tropis. Metode yang digunakan meliputi ANN yang terintegrasi dengan Principal Component Analysis (PCA), Kriging terintegrasi dengan PC, dan Kriging. Model-model tersebut dilaporkan efisien dan cepat. Hasilnya menunjukkan bahwa metodologi

tersebut dapat diterima dan sesuai untuk daerah aliran sungai perkotaan dan pesisir.

Referensi (Tan et al., 2018) berkontribusi untuk meningkatkan model prediksi ansambel dengan mengembangkan model EEMD-ANN untuk prediksi bulanan. Perbandingan kinerja dengan SVM, ANFIS, dan ANN menunjukkan peningkatan akurasi yang signifikan.

(Ravansalar, Rajae, & Kisi, 2017) membandingkan kinerja model prediksi WNN, ANN, dan model hibrida baru yang disebut wavelet linear genetic programming (WLGP) dalam menangani prediksi aliran jangka panjang. Hasil penelitian menunjukkan akurasi 0,87 untuk model WLGP. Perbandingan evaluasi kinerja menunjukkan bahwa WLGP secara signifikan meningkatkan akurasi untuk perkiraan bulanan aliran puncak

ANALISA PERFORMANSI DAN DISKUSI

Dari beberapa literatur diatas menunjukkan bahwa ANN merupakan metode Machine Learning yang sering digunakan karena keakuratan, toleransi kesalahan yang besar dan powerful dalam menangani fungsi banjir yang kompleks, terutama jika kumpulan data tidak lengkap. Namun generalisasi tetap menjadi masalah pada ANN. Dalam konteks ini, ANFIS, MLP, dan SVM berkinerja lebih baik daripada ANN. Namun, transformasi wavelet dilaporkan berguna untuk dekomposisi time series dan akan meningkatkan kemampuan sebagian besar metode ML dengan memberikan pengetahuan tentang dataset pada berbagai tingkat resolusi sebagai pra-pemrosesan data. Misalnya, WNN umumnya memberikan hasil yang lebih konsisten dibandingkan dengan ANN.

Baik dalam pemodelan curah hujan-limpasan jangka pendek atau jangka panjang, secara keseluruhan, akurasi, presisi, dan kinerja dari sebagian besar algoritma ML yang terdekomposisi (misalnya, WNN) dilaporkan lebih baik daripada yang dilatih menggunakan deret waktu tidak terdekomposisi. Namun, terlepas dari pencapaian WNN, prediksi tersebut tidak bagus untuk lead time yang lama. Untuk meningkatkan akurasi prediksi lead-time yang lebih lama hingga satu tahun, pemodelan hibrida baru seperti WARM, yang merupakan hibrid WNN dan model autoregresif, dan analisis multi-resolusi wavelet (WMRA) diusulkan. Dalam kasus lain, terlihat bahwa kinerja model meningkat pesat melalui dekomposisi untuk menghasilkan input yang lebih baik. Misalnya, model wavelet-neuro-fuzzy secara signifikan lebih akurat dan lebih cepat daripada ANFIS dan ANN tunggal. Namun, dengan bertambahnya lead time,

ketidakpastian dalam prediksi meningkat. Dengan demikian, evaluasi presisi model harus menjadi pertimbangan dalam studi selanjutnya.

Metode dekomposisi data, misalnya, autoregresif, transformasi wavelet, wavelet-autoregressive, DWT, IIS, dan EMD, memberikan kontribusi yang tinggi untuk mengembangkan metode hybrid dengan lead time prediksi yang lebih lama, stabilitas yang baik, keterwakilan yang baik, dan akurasi yang lebih tinggi. Metode dekomposisi data ini diintegrasikan dengan ANN, SVM, WNN, dan FR, dan diharapkan lebih populer. Tren lain dalam peningkatan akurasi prediksi dan kemampuan generalisasi melibatkan EPS. Faktanya, metode ensemble terkini berkontribusi pada peningkatan yang baik dalam kecepatan, akurasi, dan generalisasi. EPS dari ANN dan WNN, dengan menggunakan sampling BB, pemrograman genetik, rata-rata sederhana, stop training, Bayesian, fusi data, regresi, dan teknik komputasi lunak lainnya, menunjukkan hasil yang menjanjikan dan kinerja yang lebih baik daripada metode ML tradisional. Dalam ansambel dicatat bahwa keputusan manusia sebagai variabel input memberikan kinerja yang unggul daripada model tanpa input manusia. Namun, model hibrida yang paling signifikan adalah model prediksi dekomposisi-ansambel baru yang cocok untuk prediksi bulanan. Perbandingan kinerja mereka dengan SVM, ANFIS, dan ANN menunjukkan peningkatan yang signifikan dalam akurasi dan generalisasi.

Makalah ini menyarankan bahwa kelemahan metode ML utama dalam hal akurasi, ketidakpastian, kinerja, dan ketahanan ditingkatkan melalui hibridisasi metode ML, serta menggunakan variasi ansambel dari metode ML. Diharapkan tren ini mewakili cakrawala prediksi banjir di masa depan.

KESIMPULAN

Dalam konteks ini, ada empat tren utama yang dilaporkan dalam literatur untuk meningkatkan kualitas prediksi. Yang pertama adalah hibridisasi baru, baik melalui integrasi dua atau lebih metode pembelajaran mesin atau integrasi metode pembelajaran mesin dengan cara konvensional atau komputasi. Kedua, penggunaan teknik dekomposisi data untuk tujuan meningkatkan kualitas dataset, yang sangat berkontribusi dalam meningkatkan akurasi prediksi. Ketiga adalah penggunaan ansambel metode, yang dapat meningkatkan kemampuan generalisasi model dan menurunkan ketidakpastian prediksi. Yang keempat adalah penggunaan algoritma pengoptimal tambahan untuk meningkatkan kualitas algoritme

pembelajaran mesin, misalnya, untuk penyetelan ANN yang lebih baik guna mencapai arsitektur saraf yang optimal. Diharapkan, melalui empat teknologi utama ini, prediksi banjir akan terjadi peningkatan yang signifikan baik untuk prediksi jangka pendek maupun jangka panjang. Tentunya, kemajuan metode ML baru ini sangat bergantung pada penggunaan teknik komputasi yang tepat dalam merancang algoritme pembelajaran baru. Fakta ini dibahas dalam makalah, dan teknik komputasi diperkenalkan sebagai kontributor utama dalam mengembangkan metode ML hybrid di masa depan.

DAFTAR PUSTAKA

- Ahmad, S., & Simonovic, S. P. (2005). An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology*, 315(1–4), 236–251. <https://doi.org/10.1016/j.jhydrol.2005.03.032>
- Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H., & Lallahem, S. (2015). River Flow Model Using Artificial Neural Networks. *Energy Procedia*, 74, 1007–1014. <https://doi.org/10.1016/j.egypro.2015.07.832>
- Badan Penanggulangan Bencana Daerah (BPBD). (2013). *Disaster Management Plan of DKI Jakarta Province 2013-2017*. 50–63.
- Bappenas. (2007). *Laporan Perkiraan Kerusakan dan Kerugian Pasca Bencana Banjir Awal Februari 2007 di Wilayah JABODETABEK*. 2007, 63.
- Bass, B., & Bedient, P. (2018). Surrogate modeling of joint flood risk across coastal watersheds. *Journal of Hydrology*, 558, 159–173. <https://doi.org/10.1016/j.jhydrol.2018.01.014>
- Bhatti, H. A., Rientjes, T., Haile, A. T., Habib, E., & Verhoef, W. (2016). Evaluation of bias correction method for satellite-based rainfall data. *Sensors (Switzerland)*, 16(6), 1–16. <https://doi.org/10.3390/s16060884>
- Chang, F. J., & Chang, Y. T. (2006). Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources*, 29(1), 1–10. <https://doi.org/10.1016/j.advwatres.2005.04.015>
- Chang, F. J., Chen, P. A., Lu, Y. R., Huang, E., & Chang, K. Y. (2014). Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control. *Journal of Hydrology*, 517, 836–846. <https://doi.org/10.1016/j.jhydrol.2014.06.013>
- Cheng, G. J., Cai, L., & Pan, H. X. (2009). Comparison of extreme learning machine with support vector regression for reservoir permeability prediction. *CIS 2009 - 2009 International Conference on Computational Intelligence and Security*, 2, 173–176. <https://doi.org/10.1109/CIS.2009.124>
- Cunningham, S. C., Griffioen, P., White, M. D., & Nally, R. Mac. (2018). Assessment of ecosystems: A system for rigorous and rapid mapping of floodplain forest condition for Australia's most important river. *Land Degradation and Development*, 29(1), 127–137. <https://doi.org/10.1002/ldr.2845>
- Danso-Amoako, E., Scholz, M., Kalimeris, N., Yang, Q., & Shao, J. (2012). Predicting dam failure risk for sustainable flood retention basins: A generic case study for the wider Greater Manchester area. *Computers, Environment and Urban Systems*, 36(5), 423–433. <https://doi.org/10.1016/j.compenvurbsys.2012.02.003>
- Deo, R. C., & Şahin, M. (2015). Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia. *Atmospheric Research*, 161–162, 65–81. <https://doi.org/10.1016/j.atmosres.2015.03.018>
- Dodangeh, E., Panahi, M., Rezaie, F., Lee, S., Tien Bui, D., Lee, C. W., & Pradhan, B. (2020). Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology*, 590(August), 125423. <https://doi.org/10.1016/j.jhydrol.2020.125423>
- Doycheva, K., Horn, G., Koch, C., Schumann, A., & König, M. (2017). Assessment and weighting of meteorological ensemble forecast members based on supervised machine learning with application to runoff simulations and flood warning. *Advanced Engineering Informatics*, 33(November 2016), 427–439. <https://doi.org/10.1016/j.aei.2016.11.001>
- Elsafi, S. H. (2014). Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan. *Alexandria Engineering Journal*, 53(3), 655–662. <https://doi.org/10.1016/j.aej.2014.06.010>
- French, J., Mawdsley, R., Fujiyama, T., & Achuthan, K. (2017). Combining machine learning with computational hydrodynamics for prediction of tidal surge inundation at estuarine ports. *Procedia IUTAM*, 25, 28–35. <https://doi.org/10.1016/j.piutam.2017.09.005>
- Gazendam, E., Gharabaghi, B., Ackerman, J. D., & Whiteley, H. (2016). Integrative neural networks models for stream assessment in restoration projects. *Journal of Hydrology*, 536, 339–350. <https://doi.org/10.1016/j.jhydrol.2016.02.057>
- Ghamariadyan, M., & Imteaz, M. A. (2021). A wavelet artificial neural network method for medium-term rainfall prediction in Queensland (Australia) and the comparisons with conventional methods. *International Journal of Climatology*, 41(S1), E1396–E1416.

- <https://doi.org/10.1002/joc.6775>
Ghose, D. K. (2018). Measuring discharge using back-propagation neural network: A case study on Brahmani River Basin. In *Advances in Intelligent Systems and Computing* (Vol. 695). https://doi.org/10.1007/978-981-10-7566-7_59
- Jingyi, Z., & Hall, M. J. (2004). Regional flood frequency analysis for the Gan-Ming River basin in China. *Journal of Hydrology*, 296(1–4), 98–117. <https://doi.org/10.1016/j.jhydrol.2004.03.018>
- Ju, Q., Yu, Z., Hao, Z., Ou, G., Zhao, J., & Liu, D. (2009). Division-based rainfall-runoff simulations with BP neural networks and Xinanjiang model. *Neurocomputing*, 72(13–15), 2873–2883. <https://doi.org/10.1016/j.neucom.2008.12.032>
- Kourgialas, N. N., Dokou, Z., & Karatzas, G. P. (2015). Statistical analysis and ANN modeling for predicting hydrological extremes under climate change scenarios: The example of a small Mediterranean agro-watershed. *Journal of Environmental Management*, 154, 86–101. <https://doi.org/10.1016/j.jenvman.2015.02.034>
- Leahy, P., Kiely, G., & Corcoran, G. (2008). Structural optimisation and input selection of an artificial neural network for river level prediction. *Journal of Hydrology*, 355(1–4), 192–201. <https://doi.org/10.1016/j.jhydrol.2008.03.017>
- Lohani, A. K., Goel, N. K., & Bhatia, K. K. S. (2014). Improving real time flood forecasting using fuzzy inference system. *Journal of Hydrology*, 509, 25–41. <https://doi.org/10.1016/j.jhydrol.2013.11.021>
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S., & Elmahdi, A. (2013). Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11–21. <https://doi.org/10.1016/j.jhydrol.2013.08.035>
- Nanda, T., Sahoo, B., Beria, H., & Chatterjee, C. (2016). A wavelet-based non-linear autoregressive with exogenous inputs (WNARX) dynamic neural network model for real-time flood forecasting using satellite-based rainfall products. *Journal of Hydrology*, 539, 57–73. <https://doi.org/10.1016/j.jhydrol.2016.05.014>
- Panda, R. K., Pramanik, N., & Bala, B. (2010). Simulation of river stage using artificial neural network and MIKE 11 hydrodynamic model. *Computers and Geosciences*, 36(6), 735–745. <https://doi.org/10.1016/j.cageo.2009.07.012>
- Pereira Filho, A. J., & Dos Santos, C. C. (2006). Modeling a densely urbanized watershed with an artificial neural network, weather radar and telemetric data. *Journal of Hydrology*, 317(1–2), 31–48. <https://doi.org/10.1016/j.jhydrol.2005.05.007>
- Prasad, R., Deo, R. C., Li, Y., & Maraseni, T. (2017). Input selection and performance optimization of ANN-based streamflow forecasts in the drought-prone Murray Darling Basin region using IIS and MODWT algorithm. *Atmospheric Research*, 197, 42–63. <https://doi.org/10.1016/j.atmosres.2017.06.014>
- Ravansalar, M., Rajaei, T., & Kisi, O. (2017). Wavelet-linear genetic programming: A new approach for modeling monthly streamflow. *Journal of Hydrology*, 549(April), 461–475. <https://doi.org/10.1016/j.jhydrol.2017.04.018>
- Rezaeianzadeh, M., Tabari, H., Arabi Yazdi, A., Isik, S., & Kalin, L. (2014). Flood flow forecasting using ANN, ANFIS and regression models. *Neural Computing and Applications*, 25(1), 25–37. <https://doi.org/10.1007/s00521-013-1443-6>
- Saghafian, B., Haghnegahdar, A., & Dehghani, M. (2017). Effect of ENSO on annual maximum floods and volume over threshold in the southwestern region of Iran. *Hydrological Sciences Journal*, 62(7), 1039–1049. <https://doi.org/10.1080/02626667.2017.1296229>
- Sahoo, G. B., Ray, C., & De Carlo, E. H. (2006). Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu, Hawaii. *Journal of Hydrology*, 327(3–4), 525–538. <https://doi.org/10.1016/j.jhydrol.2005.11.059>
- Shamim, M. A., Hassan, M., Ahmad, S., & Zeeshan, M. (2016). A comparison of Artificial Neural Networks (ANN) and Local Linear Regression (LLR) techniques for predicting monthly reservoir levels. *KSCCE Journal of Civil Engineering*, 20(2), 971–977. <https://doi.org/10.1007/s12205-015-0298-z>
- Shen, H. Y., & Chang, L. C. (2013). Online multistep-ahead inundation depth forecasts by recurrent NARX networks. *Hydrology and Earth System Sciences*, 17(3), 935–945. <https://doi.org/10.5194/hess-17-935-2013>
- Tan, Q. F., Lei, X. H., Wang, X., Wang, H., Wen, X., Ji, Y., & Kang, A. Q. (2018). An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*, 567, 767–780. <https://doi.org/10.1016/j.jhydrol.2018.01.015>
- Tehrany, M. S., Pradhan, B., & Jebur, M. N. (2014). Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. *Journal of Hydrology*, 512, 332–343. <https://doi.org/10.1016/j.jhydrol.2014.03.008>
- Valipour, M., Banihabib, M. E., & Behbahani, S. M. R. (2012). Parameters estimate of autoregressive moving average and autoregressive integrated moving average models and compare their ability for inflow forecasting. *Journal of Mathematics and Statistics*, 8(3), 330–338. <https://doi.org/10.3844/jmssp.2012.330.338>

- Valipour, M., Banihabib, M. E., & Behbahani, S. M. R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 476, 433–441.
<https://doi.org/10.1016/j.jhydrol.2012.11.017>
- Xie, K., Ozbay, K., Zhu, Y., & Yang, H. (2017). Evacuation Zone Modeling under Climate Change: A Data-Driven Method. *Journal of Infrastructure Systems*, 23(4), 04017013.
[https://doi.org/10.1061/\(asce\)is.1943-555x.0000369](https://doi.org/10.1061/(asce)is.1943-555x.0000369)
- Young, C. C., Liu, W. C., & Wu, M. C. (2017). A physically based and machine learning hybrid approach for accurate rainfall-runoff modeling during extreme typhoon events. *Applied Soft Computing Journal*, 53, 205–216.
<https://doi.org/10.1016/j.asoc.2016.12.052>
- Yu, P. S., Yang, T. C., Chen, S. Y., Kuo, C. M., & Tseng, H. W. (2017). Comparison of random forests and support vector machine for real-time radar-derived rainfall forecasting. *Journal of Hydrology*, 552, 92–104.
<https://doi.org/10.1016/j.jhydrol.2017.06.020>