Fidelity : Jurnal Teknik Elektro p-ISSN: 2686-3650 Vol. 1, No. 1, Mei 2019, page 20-24 e-ISSN: 2686-3642

Penggabungan Struktur Kernel untuk Desain Jaringan Saraf Hibrida

Ade Ramdani Science Teacher MAN 4 Sukabumi Sukabumi, Indonesia ramdanieade@gmail.com

Abstrak-Makalah ini bertujuan untuk mengembangkan classifier jaringan saraf tiruan berbasis fusi struktur kernel untuk meningkatkan kinerja jaringan BP dan RBF tunggal. Solusi yang diusulkan tidak bergantung pada kerangka kerja jaringan RBF dan BP tunggal. Jaringan yang menyatu dapat secara efektif mengekstrak karakteristik lokal dari distribusi spasial sampel dan pembelajaran dan klasifikasi non-linier dalam ruang kernel Gaussian dengan membangun mekanisme koneksi yang efektif antara kernel Gaussian dengan parameter berbeda dan kernel sigmoid di lapisan tersembunyi yang berbeda. Kelebihan jaringan RBF dan BP digabungkan dalam bentuk jaringan yang menyatu. Dalam jaringan RBF dan BP tunggal, ini secara efektif menurunkan ketergantungan pada pemilihan parameter node tersembunyi. Eksperimen pada dua set data simulasi dan tiga set data benchmark menunjukkan bahwa topologi jaringan yang diusulkan lebih disukai.

Kata Kunci—inti; Fusi Struktur; hibrida; jaringan saraf

I. PENGANTAR

Di dunia sekarang ini, jaringan saraf banyak digunakan di berbagai sektor, termasuk kategorisasi gambar, diagnosis medis, dan sebagainya. Jaringan BP [1] dan jaringan RBF [2] adalah dua model jaringan yang paling banyak digunakan di antara semua jenis jaringan saraf. Fungsi kernel dan mekanisme pemetaan yang digunakan oleh node tersembunyi jaringan yang berbeda adalah perbedaan mendasar dalam menentukan model jaringan. Fungsi kernel yang digunakan oleh node tersembunyi di jaringan saraf BP, misalnya, adalah kernel sigmoid dengan karakteristik respons global yang kuat. Aturan pembelajarannya menggunakan metode penurunan gradien berdasarkan propagasi balik kesalahan untuk memperbarui bobot jaringan secara iteratif, mengurangi jumlah kesalahan kuadrat dari keluaran jaringan. Kelemahan mendasar jaringan BP adalah kecepatan konvergensi yang lambat vang sering jatuh ke minimum lokal. Skenario ini menjadi lebih parah saat level tersembunyi jaringan tumbuh.

Model jaringan saraf standar lainnya adalah jaringan RBF. Berbeda dengan BP Neural Network, fungsi kernel yang digunakan oleh node tersembunyi adalah fungsi radial basis, yang memiliki karakteristik respon lokal yang baik. Kernel Gauss adalah kernel fungsi basis radial yang paling sering dalam jaringan RBF. Oleh karena itu, keterpisahan ruang sampel asli dapat ditingkatkan secara efektif dengan memetakan kernel Gauss n. Kemudian, pengklasifikasi linear seperti LMS dan RLS ditautkan untuk menyelesaikan klasifikasi ruang kernel. Namun, untuk masalah klasifikasi yang rumit, jika pemilihan parameter simpul tersembunyi

salah, pemetaan kernel Gauss yang salah dapat meningkatkan beban proses pemutakhiran bobot.

Penelitian ini menyajikan pengklasifikasi jaringan saraf hibrida berdasarkan fusi struktur kernel untuk meningkatkan kinerja jaringan jaringan BP dan RBF tunggal dan menghilangkan ketergantungan pada pemilihan parameter node tersembunyi di jaringan BP dan RBF. Jaringan yang menyatu dapat secara efektif mengekstrak properti lokal dari spasial sampel dengan mengembangkan mekanisme koneksi yang efektif antara kernel Gaussian dengan parameter yang bervariasi dan kernel sigmoid di lapisan tersembunyi jaringan BP. Selanjutnya, dengan menggunakan beberapa kernel Gaussian, pemetaan sampel input dapat secara efektif meningkatkan keterpisahan ruang sampel. Jaringan BP berjenjang kemudian menyelesaikan pembelajaran non-linier dan klasifikasi jaringan di ruang kernel Gaussian. Akibatnya, pendekatan yang diusulkan dapat menggabungkan manfaat jaringan RBF dan jaringan BP sambil juga mengatasi kelemahan jaringan BP tunggal dan jaringan RBF.

Setelah pembentukan struktur jaringan hibrid, implementasi algoritma jaringan saraf hibrid fusi harus diselesaikan. Algoritma pembelajaran jaringan saraf hibrida dipecah menjadi dua bagian. Untuk memulainya, algoritma fuzzy C-means clustering digunakan untuk menentukan parameter dari kernel Gaussian. Pendekatan propagasi balik dengan penurunan gradien stokastik kemudian memperbarui parameter bobot yang terkait dengan kernel sigmoid.

Jaringan fungsi basis radial (RBF) berdasarkan algoritma "fuzzy C-means, RLS" dibandingkan dengan jaringan BP berdasarkan penurunan gradien stokastik dan jaringan fungsi basis radial (RBF) berdasarkan "fuzzy C-means, RLS" mendekati. Hasil eksperimen menunjukkan bahwa struktur jaringan yang diusulkan lebih disukai.

II. PENELITIAN TERKAIT

Para peneliti telah mencari berbagai cara untuk meningkatkan defisit jaringan BP dan RBF. Mayoritas pendekatan yang ada, di sisi lain, berpusat pada peningkatan struktur jaringan tunggal. Bobot inisialisasi berdasarkan optimasi global [3,4], penambahan suku momentum ke gradien lokal [5,], penyesuaian adaptif kecepatan pembelajaran [6,], modifikasi fungsi biaya kesalahan [7], dan penyesuaian dinamis struktur jaringan [8] adalah beberapa contoh pendekatan tipikal untuk mengoptimalkan jaringan BP.

Tantangan paling kritis dalam jaringan RBF adalah menentukan jumlah kernel dan mengoptimalkan parameter kernel. Keandalan pemetaan kernel dapat ditingkatkan ke derajat yang berbeda dengan mengubah jumlah butir dan parameter benih untuk berbagai masalah klasifikasi. Jaringan alokasi sumber daya minimum (MRAN) [9] adalah metode standar untuk menentukan jumlah kernel.

- GAP-RBF [10] adalah teknik pembelajaran berurutan untuk menumbuhkan dan memangkas RBF
- Desain inkremental jaringan fungsi basis radial lainnya [11, 12].

K-means clustering [13], fuzzy C-means clustering [14], algoritma seleksi maju ortogonal [15], algoritma evolusioner [16], dan lebih banyak pendekatan yang ada untuk mengoptimalkan parameter kernel jaringan. Setelah menentukan jumlah kernel dan parameter kernel, bobot keluaran dioptimasi menggunakan teknik klasifikasi linier seperti LMS atau RLS. Namun, subjek mengoptimalkan struktur jaringan RBF dan pengaturan kernel tetap tidak terjawab.

Jaringan saraf umpan maju bertingkat [17,18] telah digunakan di beberapa sektor untuk mewujudkan interkoneksi topologi jaringan saraf yang beragam. Perlu dicatat bahwa jaringan saraf bertingkat terdiri dari koneksi beberapa sub-jaringan yang berbeda, yang masing-masing otonom. Setiap sub-jaringan digunakan untuk mengatasi sub-masalah yang berbeda ketika mengelola masalah yang signifikan menjadi beberapa sub-masalah. Tujuan utamanya adalah untuk menggabungkan solusi saat ini untuk memecahkan masalah serupa. Cara menggabungkan dan memodifikasi berbagai jenis jaringan saraf untuk pekerjaan klasifikasi tertentu adalah pekerjaan yang perlu ditelusuri dari perspektif struktur jaringan.

Jaringan saraf umpan maju bertingkat [17,18] telah digunakan di beberapa sektor untuk mewujudkan interkoneksi topologi jaringan saraf yang beragam. Perlu dicatat bahwa jaringan saraf bertingkat terdiri dari koneksi beberapa sub-jaringan yang berbeda, yang masing-masing otonom. Setiap sub-jaringan digunakan untuk mengatasi sub-masalah yang berbeda setelah membagi masalah yang kompleks menjadi banyak sub-masalah. Tujuan utamanya adalah untuk menggabungkan solusi saat ini untuk memecahkan masalah serupa. Cara menggabungkan dan memodifikasi beberapa jenis jaringan saraf untuk pekerjaan klasifikasi tertentu adalah pekerjaan yang perlu ditelusuri dari perspektif struktur jaringan.

III. JARINGAN SYARAF HIBRIDA BERDASARKAN STRUKTUR FUSION KERNEL

Gambar 1 menunjukkan dampak pemetaan kernel Gauss dengan berbagai nilai untuk menunjukkan karakteristik dan manfaat dari metode yang diusulkan. Ruang sampel latihan pertama-tama dilokalisasi menggunakan kernel Gaussian yang digabungkan ke sampel input. Kemudian memetakan perwakilan wilayah lain ke simpul unit hypercube, secara signifikan meningkatkan keterpisahan ruang sampel. Pembelajaran dan klasifikasi jaringan BP kemudian diselesaikan dalam ruang kernel Gaussian. Kualitas lokal kernel Gaussian dan karakteristik respon global kernel sigmoid dapat digabungkan secara efisien dengan cara ini.

Jumlah kernel Gaussian harus K. Ketika sampel input arbitrer $x \in R^t$ melewati kernel Gaussian. Kemudian, hubungan pemetaan terlokalisasi dapat ditulis sebagai $f: R^t \to (0,1]^K$. Dalam metode ini, bentuk geometris dari distribusi sampel dalam ruang sampel dapat digunakan sebagai fitur pemetaan untuk membuat vektor fitur baru, meningkatkan yang asli keterpisahan ruang sampel. Setelah itu, jaringan BP non-linier dapat digunakan untuk menyelesaikan klasifikasi efektif sampel ruang fitur menggunakan pemetaan kernel Gaussian. Dengan asumsi bahwa keterpisahan ruang sampel ditingkatkan, risiko minimum lokal dapat dihindari, dan kecepatan konvergensi jaringan dapat dipercepat Sebagai hasilnya, jaringan BP yang disediakan berdasarkan fusi kernel dapat secara efektif meningkatkan jaringan BP.

Gambar 2 menggambarkan konstruksi jaringan saraf BP berdasarkan fusi kernel dalam makalah ini, seperti yang dijelaskan sebelumnya. Tiga komponen membentuk struktur jaringan yang disajikan:

- 1. Lapisan satu adalah lapisan masukan. Lapisan ini memiliki t node, di mana t adalah jumlah dimensi dalam sampel input \mathbf{x} .
- 2. Lapisan fusi nomor dua. Lapisan ini terdiri dari kernel Gaussian dengan parameter yang bervariasi dan kernel sigmoid dengan parameter yang sama. Node input dan kernel Gaussian memiliki bobot koneksi satu. Bobot yang menghubungkan biji Gaussian dan butir sigmoid diinisialisasi secara acak. Ketika jumlah sumber adalah c, pemetaan kernel Gaussian ke sampel input x dapat ditulis sebagai:

$$\phi_j(x) = exp(-\frac{1}{2\sigma_j^2}||x - \mu_j||^2), j = 1, 2, ... c$$
(1)

Pusat dan lebar kernel Gaussian ke-j diwakili oleh parameter μ_j dan σ_j , masing-masing. Node ke-j dari lapisan sigmoid ke-l mendorong medan lokal untuk digambarkan sebagai ketika $\phi_j(x)$ melewati lapisan sigmoid pertama.

$$v_j^{(l)} = \sum_i \omega_{ji}^{(l)} y_i^{(l-1)}$$
 (2)

Dimana $\omega_{ji}^{(l)}$ adalah output dari node ke-i dari layer l-1, dan $y_i^{(l-1)}$ adalah bobot dari node ke-i dari layer l-1 ke layer l. Fungsi tangen hiperbolik digunakan sebagai kernel sigmoid dalam makalah ini.

$$y_j^{(l)} = atanh(bv_j) \tag{3}$$

di mana a dan b adalah konstanta.

Jika l=1, simpul j berada di lapisan sigmoid pertama, dan kita dapat menurunkan yang berikut.

$$y_j^{(0)} = \phi_j(x) \tag{4}$$

3. Lapisan keluaran. Node keluaran ke-i dari jaringan hybrid berdasarkan fusi kernel dilambangkan dengan.

$$O_i(n) = y_i^{(L)} \tag{5}$$

dimana L berada pada lapisan sigmoid terakhir.

Setelah pembentukan struktur jaringan hybrid, tujuan selanjutnya adalah untuk menyelesaikan implementasi algoritma dari fused hybrid neural network. Langkah-langkah algoritma pembelajaran jaringan adalah sebagai berikut:

- 1. Inisialisasi adalah langkah pertama. Pertama, jumlah kernel Gaussian, lapisan tersembunyi, dan node dari komponen jaringan BP sudah diatur, dan parameter bobot komponen jaringan BP diinisialisasi secara acak.
- 2. Pengelompokan sampel pelatihan menggunakan fuzzy c-means. Tabel 1 menampilkan algoritma implementasi tertentu.
- 3. Pengelompokan menunjukkan bahwa pusat fungsi kernel Gaussian adalah $\mu_j(j=1,2,...,c)$. Untuk menghitung setiap nilai pemetaan, saya menggunakan (2). Jarak Euclidean antara semua pusat diberikan oleh himpunan $\sigma=d_{max}/\sqrt{2c}$
- 4. Ambang ε ditetapkan sebagai kondisi penghentian iterasi. Input kernel sigmoid ditetapkan ke nilai pemetaan kernel Gaussian $\varphi(x)$, dalam hal ini, $\varphi(x) = (\varphi_1(x), \varphi_2(x), ..., \varphi_c(x))$.
- 5. Melakukan perhitungan forward bobot jaringan yang terkait dengan setiap kernel sigmoid menggunakan (2)-(5).
- 6. Menghitung fungsi kesalahan kuadrat rata-rata jaringan.
- 7. Perhitungan mundur dari gradien lokal jaringan yang disediakan

$$\delta_{i}^{(l)} = e_{i}^{(L)} \phi'_{i}(v_{i}^{(L)})$$

untuk simpul j di lapisan keluaran L

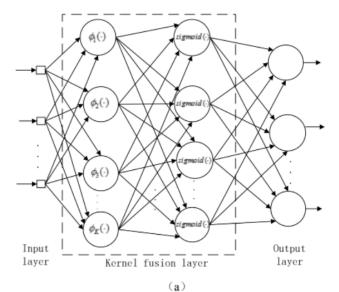
$$\delta_{j}^{(l)} = \phi'_{j}(v_{j}^{(L)}) \sum_{k} \delta_{k}^{(l+1)} w_{kj}^{(l+1)}$$
(6)

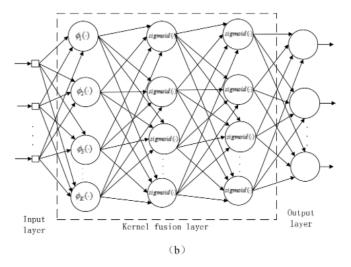
untuk simpul j di lapisan sigmoid l

8. Memperbarui bobot setiap lapisan yang terhubung ke kernel sigmoid

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \eta \delta_{j}^{(l)}(n) y_{i}^{(l-1)}(n)$$
(7)

di mana η adalah kecepatan pembelajaran, n adalah langkah iterasi.





Gambar 2. Jaringan saraf hybrid berdasarkan fusi struktur kernel. (a) Dengan lapisan RBF dan lapisan kaskade sigmoid tunggal(b)Dengan lapisan RBF dan dua lapisan kaskade sigmoid

9. Lapisan jaringan yang terhubung ke kernel sigmoid diulang. Algoritma menyimpulkan setelah menyajikan sampel putaran baru ke jaringan yang diusulkan dan perhitungan iteratif menggunakan langkah 5-8 sampai $j(\omega) < \varepsilon$.

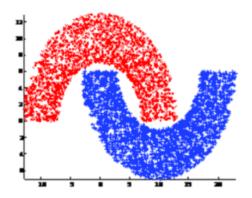
IV. JARINGAN SYARAF HIBRIDA BERDASARKAN STRUKTUR FUSION KERNEL

Dua set data palsu [24] dan tiga set data benchmark UCI [25] disajikan dalam penelitian ini untuk menguji kinerja jaringan yang diusulkan, dan jaringan yang diusulkan dibandingkan dengan jaringan saraf BP berdasarkan penurunan gradien stokastik dan jaringan RBF dengan kernel Gaussian. Validasi silang digunakan untuk mengoptimalkan jumlah unit lapisan tersembunyi di jaringan BP dan RBF. Semua algoritma dijalankan di lingkungan yang sama. Istilah momentum α untuk jaringan BP dipilih dari himpunan [0.1,0.2,0.3]. 0 dipilih untuk jaringan BP yang disajikan dengan fusi kernel. Atur nilai pembelajaran kernel sigmoid ke 1,716, b 2 / 3 untuk hasil terbaik. Setiap percobaan dilakukan sepuluh kali dengan menggunakan prosesor Intel (R) Core (TM) i5 dengan

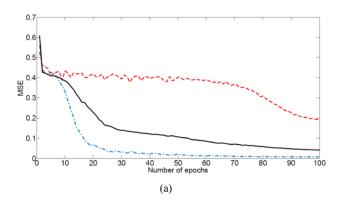
kecepatan clock 3,2 GHz, RAM 4 GB, dan MATLAB 2013. Dataset klasifikasi tercantum pada Tabel II.

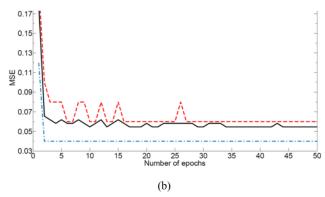
Kumpulan data	Jumlah kelas	Jumlah fitur	Contoh pelatihan	Sampel pengujian
bulan ganda	2	2	300	4000
Memutar	2	2	500	4000
Diabetes	2	8	576	192
German credit (GC)	2	24	200	151
Ionosfir	2	34	500	500

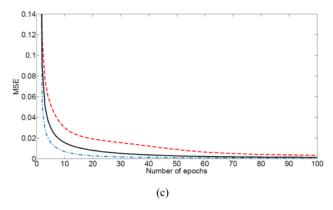
A. Masalah klasifikasi bulan ganda



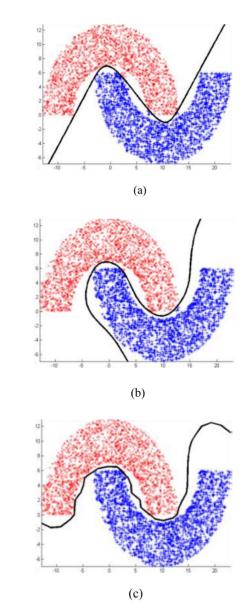
Gambar 3. Dataset klasifikasi bulan ganda







Gambar 4. Perbandingan kurva pembelajaran kesalahan kuadrat rata-rata jaringan yang berbeda pada dataset Bulan Ganda. (a) Jaringan BP (b) Jaringan RBF (c) Jaringan Saraf Hibrida Berdasarkan Fusi Struktur Kernel



Gambar 5. Perbandingan efek kategorisasi jaringan yang berbeda pada dataset Bulan Ganda. Jaringan BP (a) Jaringan RBF (b) Hybrid Neural Network Berdasarkan Fusi Struktur Kernel (c) Hybrid Neural Network Berdasarkan Fusi Struktur Kernel

Representasi grafis dari dataset klasifikasi bulan ganda ditunjukkan pada Gambar 3. Kurva pembelajaran kesalahan kuadrat rata-rata dari jaringan yang disajikan, serta jaringan BP dan RBF, ditunjukkan pada Gambar. 4, dengan garis putus-putus merah mewakili maksimum kurva pembelajaran kesalahan kuadrat rata-rata, garis putus-putus biru mewakili kurva pembelajaran kesalahan kuadrat rata-rata minimum, dan garis hitam pekat masing-masing mewakili kurva pembelajaran kesalahan kuadrat rata-rata rata-rata. Jumlah lapisan sigmoid diatur ke satu. Tata letak jaringan yang disediakan secara substansial meningkatkan kecepatan konvergensi jaringan BP tunggal, dan kesalahan kuadrat rata-ratanya dapat menyatu ke nilai yang lebih rendah. Dibandingkan dengan jaringan RBF, topologi yang diberikan mewarisi keunggulan jaringan RBF dari stabilitas yang solid. Kesalahan kuadrat rata-rata konvergen dengan cepat dalam sepuluh putaran pertama dari proses iterasi. Kesalahan kuadrat rata-rata jaringan saat ini semakin diturunkan seiring dengan meningkatnya ukuran langkah iterasi, sehingga dampak pembelajaran berhasil ditingkatkan.

Gambar 5 menunjukkan perbandingan eksperimental dalam satu dan dua lapisan sigmoid tersembunyi di bawah berbagai parameter untuk menentukan pengaruh jumlah kernel Gaussian dalam jaringan yang diusulkan. Dapat ditunjukkan bahwa menyesuaikan jumlah lapisan sigmoid dan node tersembunyi sambil menjaga jumlah kernel Gaussian dalam rentang tertentu mengurangi kesalahan kuadrat rata-rata dalam kumpulan sampel pelatihan sekaligus meningkatkan akurasi klasifikasi dalam kumpulan pengujian. Jaringan BP non-linier tertaut berikut dapat memberikan klasifikasi unggul berdasarkan pembelajaran pemetaan kernel ruang sampel pelatihan. Akibatnya, jaringan yang diberikan menggabungkan keunggulan stabilitas solid kernel Gaussian dengan kemampuan generalisasi kernel sigmoid yang sangat baik. Ini menyederhanakan jumlah biji Gaussian dan butiran sigmoid di lapisan fusi, menghasilkan kinerja klasifikasi yang relatif lebih tinggi untuk seluruh jaringan.

V. Kesimpulan

Sebuah jaringan hybrid berdasarkan fusi struktur kernel disajikan dalam makalah ini. Jaringan yang menyatu dapat secara efektif mengekstrak karakteristik lokal dari distribusi spasial sampel dengan membangun mekanisme koneksi yang efektif antara kernel Gaussian dengan parameter yang berbeda dan kernel sigmoid di lapisan tersembunyi yang berbeda, yang menggabungkan keunggulan jaringan RBF dan BP dan mengurangi ketergantungan pada pemilihan parameter node tersembunyi dalam jaringan RBF dan BP tunggal. Eksperimen pada kumpulan data palsu dan benchmark mengungkapkan bahwa teknik yang diusulkan dapat secara signifikan meningkatkan kinerja generalisasi dan kecepatan konvergensi jaringan BP.

REFERENSI

- D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations of back-propagating errors," Nature, vol. 323, pp. 533-536, 1986.
- [2] D. S. Broomhead, and D. Lowe, "Multivariable function interpolation and adaptive network," Complex Systems, vol. 2, pp. 321-355, 1988.
- [3] Y. Liu, J. Yang, L. Li and W. Wu, "Negative effects of sufficiently small initial weights on back-propagation neural networks," Journal of Zhejiang University-SCIENCE C-Computers & Electronics, vol. 13, pp. 585-592, 2012.

- [4] S. F. Ding, C. Y. Su and J. Z. Yu, "An optimizing BP neural network algorithm based on genetic algorithm," Artificial Intelligence Review, vol. 36, pp. 153-162, 2011.
- [5] A. Bhaya, and E.Kaszkurewicz, "Steepest descent with momentum for quadratic functions is a version of the conjugate gradient method," Neural Networks, vol. 17, pp. 65-71, 2004.
- [6] J. E. Vetela and J. Reifman, "Premature saturation in back-propagation networks: mechanism and necessary conditions," Neural Networks, vol. 10, pp. 721-735, 1997.
- [7] C. H. Chen, T. K. Yao, C. M. Kuo and C.Y. Chen, "Evolutionary design of constructive multilayer feedforward neural network," Journal of Vibration and Control, vol. 19, pp. 2413-2420, 2013.
- [8] S. Amari, "A theory of adaptive pattern classifiers," IEEE Transactions on Electronic Computers, vol. 16, pp. 299-307, 1967.
- [9] L. Yingwei, N. Sundararajan and P. Saratchandran, "A sequential learning scheme for function approximation using minimal radial basis function," Neural Computation, vol. 9, pp. 461–478, 1997.
- [10] G-B. Huang, P. Saratchandran and N. Sundararajan, "A generalized growing and pruning RBF (GAP-RBF) neural network for function approximation," IEEE Trans. Neural. Netw. vol. 16, 57-67, 2005.
- [11] H. Yu, P. D. Reiner, T. Xie, T. Bartczak and B. M. Wilamowski, "An incremental design of radial basis function networks," IEEE Trans. Neural Netw. and Learning Systems, vol. 2, pp. 1793–1803, 2014.
- [12] S. Suresh, D. Keming, H. J. Kim, "A sequential learning algorithm for self-adaptive resource allocation network classifier," Neurocomputing, vol. 73, pp. 3012-3019, 2010.
- [13] J. Moody and C. J. Darken, "Fast learning in networks of locally-tuned processing," Neural Computation, 1989, vol. 1, pp. 281-294, 1989.
- [14] A. D. Niros and G. E. Tsekouras, "A novel training algorithm for RBF neural network using a hybrid fuzzy clustering approach," Fuzzy Sets and Systems, vol. 193, pp. 62-84, 2012.
- [15] S. Chen, X. Hong, C. J. Harris and L. Hanzo, "Fully complex-valued radial basis function networks: Orthogonal least squares regression and classification," Neurocomputing, vol. 71, pp. 3421-3433, 2008.