

Analisis Produktivitas Kinerja Dosen dan Tenaga Kependidikan dalam Mewujudkan Tahun Reputasi Universitas Negeri Semarang (UNNES) Menggunakan Jaringan Saraf Tiruan

Walid, Sugiman, Sunarmi, Dian Tri Wiyanti
Universitas Negeri Semarang (UNNES)

Abstrak

Produktivitas sebagai suatu ukuran pada kualitas dan kuantitas dari pekerjaan yang telah dikerjakan dengan mempertimbangkan biaya dan sumber daya yang digunakan untuk mengerjakan pekerjaan tersebut. Hal ini menunjukkan bahwa produktivitas kinerja dosen dan karyawan adalah suatu konsep yang menunjukkan adanya kaitan antara hasil kerja dengan satuan waktu yang dibutuhkan untuk menghasilkan produk dari semua unit satuan yang ada di kampus. Produktivitas di lingkungan Universitas Negeri Semarang (UNNES) merupakan suatu interkasi terpadu secara serasi dari tiga faktor esensial, yaitu optimalisasi kemampuan, manajemen dan sumber daya yang dimiliki oleh UNNES. Pemberian motivasi kepada seluruh civitas akademika UNNES sangatlah berpengaruh terhadap jalannya kemajuan UNNES dalam mewujudkan tahun reputasi yang dicanangkan pada tahun 2017 ini. Jaringan saraf tiruan sebagai salah satu sistem pemrosesan informasi yang didesain dengan menirukan cara kerja otak manusia dalam menyelesaikan suatu masalah dengan melakukan proses belajar melalui perubahan bobot sinapsisnya dapat digunakan untuk melakukan analisis terhadap produktivitas kinerja dosen dan karyawan UNNES dalam mewujudkan tahun reputasi yang dicanangkan pada tahun 2017. Penelitian berkaitan dengan pengembangan jaringan saraf tiruan telah cukup banyak dilakukan oleh ahli dibidang ini, antara lain hasil penelitian yang dilakukan oleh Walid dkk (2015) tentang peramalan menggunakan model jaringan saraf tiruan pada data *berpola long memory* dengan konsentrasi ada penggunaan beban konsumsi listrik PLN di Jawa dan Bali. Dalam penelitian ini akan dikembangkan model analisis produktivitas kinerja dosen dan tenaga kependidikan dalam mewujudkan tahun reputasi UNNES menggunakan jaringan saraf tiruan. Adapun faktor-faktor yang digunakan untuk mengukur tingkat produktivitas antara lain: 1. Pengetahuan (*knowledge*), 2. keahlian (*skill*), 3. Kemampuan (*capability*), 4. Sikap (*attitude*) dan 5. Perilaku (*behavior*). Kelima aspek tersebut yang akan dijadikan alat ukur untuk menganalisis produktivitas civitas akademika UNNES. Berdasarkan analisis akan diperoleh sebesar pengaruh yang diberikan oleh masing-masing aspek dalam kontribusinya mewujudkan tahun reputasi sekaligus dapat diketahui aspek-aspek mana saja yang masih harus ditingkatkan. Penelitian ini akan dilaksanakan dengan studi literatur, simulasi dan metode kuesioner dengan responden dosen dan tenaga kependidikan UNNES, dengan mengambil sampel representatif di fakultas MIPA. Hasil penelitian ini menunjukkan bahwa data-data yang dikumpulkan melalui kuesioner kemudian diberikan pelatihan dan diuji menunjukkan bahwa faktor pengetahuan, keahlian, kemampuan sikap dan perilaku yang baik tidak selalu menunjukkan produktivitas yang baik. Namun demikian ada dua faktor yang cukup dominan dalam mempengaruhi ketercapaian tahun reputasi di FMIPA UNNES tahun 2017 yaitu faktor pengetahuan dan perilaku.

Kata kunci : Jaringan Saraf Tiruan, Produktivitas, Tahun Reputasi

PENDAHULUAN

Sejalan dengan kebijakan Kemenristek Dikti yang salah satu tujuannya adalah untuk menciptakan keunggulan penelitian di perguruan tinggi, LP2M Unnes mengembangkan program penelitian khusus yang memberikan keleluasaan kepada perguruan tinggi untuk mengembangkan penelitian unggulannya (PUPT). Penelitian PUPT adalah penelitian yang mengacu pada bidang unggulan yang telah ditetapkan dalam Renstra LP2M Unnes. Penelitian

terarah dan bersifat *top-down* dengan dukungan dana, sarana dan prasarana penelitian dari perguruan tinggi serta *stakeholders* yang memiliki kepentingan secara langsung maupun tidak langsung. Sasaran akhir dari penelitian ini adalah dihasilkannya inovasi teknologi pada bidang-bidang unggulan (*frontier*) dan rekayasa sosial guna meningkatkan pembangunan berkelanjutan pada tingkat lokal maupun nasional.

Universitas Negeri Semarang (UNNES) telah menetapkan tahun 2017 ini merupakan tahun reputasi, salah satu target untuk Tahun Reputasi adalah meningkatkan publikasi ilmiah Dosen dan Mahasiswa, baik di tingkat nasional maupun internasional. Oleh karena itu upaya untuk meningkatkan publikasi dosen-dosen, terutama untuk publikasi ilmiah tingkat internasional menjadi salah satu agenda penting. Selain itu, juga akan mendorong mahasiswa-mahasiswa, terutama mahasiswa kelas internasional untuk mengikuti berbagai kegiatan yang berskala internasional.

Perkembangan ilmu pengetahuan begitu dinamis dan kompleks, salah satunya perkembangan di bidang Jaringan saraf tiruan (JSN). JSN merupakan model nonparametrik yang mempunyai bentuk fungsional yang fleksibel, mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik. Dalam penerapannya, JSN mengandung sejumlah parameter (*weight*) yang terbatas. Bagaimana mendapatkan model JSN yang sesuai, yaitu bagaimana menentukan kombinasi yang tepat antara jumlah variabel *input* dan jumlah unit pada *hidden layer* (yang berimplikasi pada jumlah parameter yang optimal), merupakan topik sentral dalam beberapa literatur JSN yang telah banyak dibahas pada banyak artikel dan banyak buku seperti pada Bishop (1995), Ripley (1996), Fine (1999), Haykin (1999).

Penelitian lain telah berhasil menerapkan sub peta *intermittency* untuk pemodelan lalu lintas internet, yang merupakan contoh yang berhubungan namun berbeda dengan fenomena yang menunjukkan *long memory* dan distribusi *marginal* dapat dilihat pada Park dan Wilinger (2000). Dewasa ini banyak penelitian yang menggunakan model peramalan dengan menggunakan *neural network* pada berbagai bidang, antara lain di bidang pelabelan, pembelajaran konteks bahasa dan bidang kelistrikan (lihat pada chen (1995), Husen (2001), Taylor (2003), Taylor, Menezes dan McSharry (2006) dan Ristiana (2008)). Walid dkk (2015) mengembangkan *fractional integrated recurrent neural network* (FIRNN) atau JSN pada model pola data yang *long memory*, untuk peramalan data runtun waktu dengan aplikasi beban listrik di Jawa-Bali. Sedangkan penelitian yang mengembangkan efek data *outlier* dapat dilihat (soney Sunaryo dkk, 2011).

Berdasarkan uraian di atas, akan dikembangkan suatu kajian keilmuaan tentang penggunaan jaringan saraf tiruan pada produktivitas kualitas dan kuantitas pekerjaan di Unnes dengan mempertimbangkan biaya dan sumber daya. Hal ini menunjukkan bahwa produktivitas kinerja dosen dan karyawan adalah suatu konsep yang menunjukkan adanya kaitan antara hasil kerja dengan satuan waktu yang dibutuhkan untuk menghasilkan produk dari semua unit satuan yang ada di kampus. Dalam penelitian ini akan dikembangkan model analisis produktivitas kinerja dosen dan tenaga kependidikan dalam mewujudkan tahun reputasi UNNES menggunakan jaringan saraf tiruan. Adapun faktor-faktor yang digunakan untuk mengukur tingkat produktivitas antara lain: 1. Pengetahuan (*knowledge*), 2. keahlian (*skill*), 3. Kemampuan (*capability*), 4. Sikap (*attitude*) dan 5. Perilaku (*behavior*). Kelima aspek tersebut yang akan dijadikan alat ukur untuk menganalisis produktivitas civitas akademika UNNES. Berdasarkan analisis akan diperoleh sebesar besar pengaruh yang diberikan oleh masing-masing aspek dalam kontribusinya mewujudkan tahun reputasi sekaligus dapat diketahui aspek-aspek mana saja yang masih harus ditingkatkan.

Berdasarkan hal tersebut, fokus permasalahan dalam penelitian ini adalah sebagai berikut. (1) Bagaimana produktivitas kinerja dosen dan tenaga kependidikan dalam mewujudkan tahun reputasi Universitas Negeri Semarang (UNNES) menggunakan jaringan saraf tiruan? (2) Faktor-faktor apa sajakah yang sangat berpengaruh dalam produktivitas kinerja dosen dan tenaga kependidikan guna mewujudkan tahun reputasi Universitas Negeri Semarang (UNNES) menggunakan jaringan saraf tiruan?

METODE

Pengumpulan data dilakukan dengan menggunakan metode kuesioner dengan responden Dosen dan Tenaga Kependidikan dilingkungan Universitas Negeri Semarang. Masing-masing unit kerja dan fakultas diambil 5 pegawai di 8 fakultas ditambah pada beberapa unit dan pascasarjana, sehingga total responden yang diambil sebagai sampel dalam penelitian sebanyak 100 responden. Untuk kemudahan dalam analisis data, maka data hasil kuesioner akan diubah kedalam bentuk matriks atau numerik. Kelima variabel yang dipakai adalah X1: pengetahuan, X2: Keahlian, X3: Kemampuan, X4: Sikap dan X5: Perilaku.

Metode analisis data yang digunakan dalam penelitian ini adalah metode analisis data didasarkan pada kajian teori, kajian komputasi dan kajian terapan. Berdasarkan fokus penelitian tersebut, tahapan penelitian ini dijabarkan secara detail dalam pemaparan berikut.

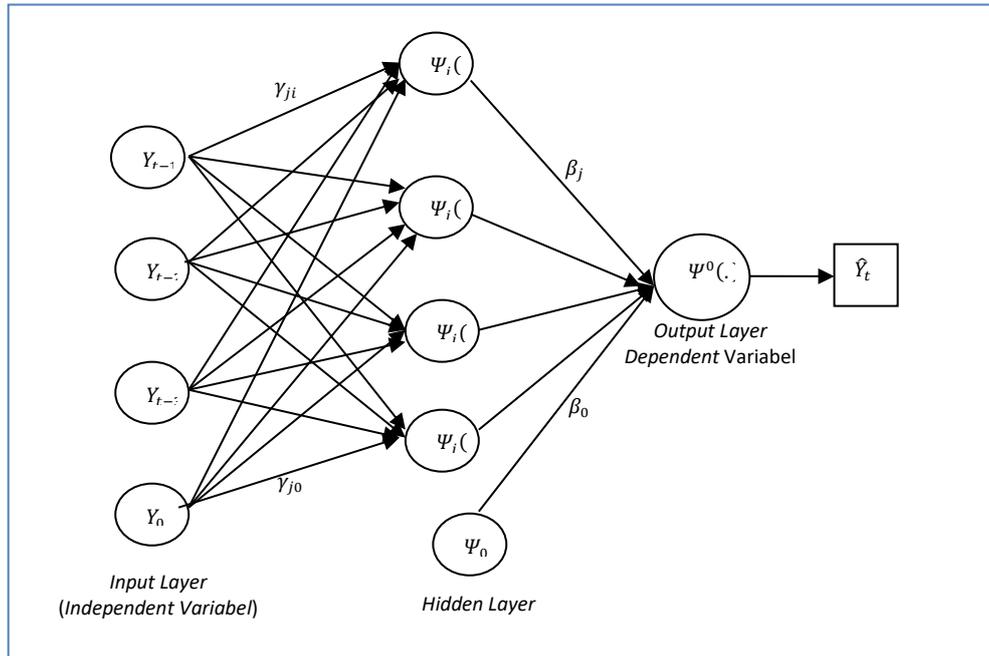
Studi *literature* dan kajian teoritis mendalam dilakukan untuk memperoleh kajian identifikasi data yang memuat model jaringan saraf tiruan, produktivitas pegawai dengan menggunakan model lima variabel yang telah ditentukan di atas. Kelima variabel yang menjadi objek dalam objek dalam penelitian ini akan dikaji secara teoritis. Selain itu untuk memperoleh kajian pemetaan terhadap penggunaan aplikasi model jaringan saraf tiruan yang berkembang saat ini diaji secara mendalam sebagai dasar penggunaan keilmuaan untuk menganalisis kondisi yang sebenarnya.

Dalam kajian komputasi ini dilakukan untuk memperoleh hasil analisis dengan menggunakan jaringan saraf tiruan dan komputasional tahap-tahap identifikasi data yang memuat penentuan variabel, penyusunan fokus pada pemilihan indikator disetiap variabel yang menjadi objek pilihan data pada penelitian ini. Analisis selanjutnya dilakukan simulasi dan analisis komputasional model jaringan saraf tiruan pada data yang memuat variabel-variabel yang menjadi objek penelitian dengan menggunakan simulasinya menggunakan program MATLAB.

HASIL DAN PEMBAHASAN

Multi Layer Perceptrons yang juga dikenal dengan *feedforward neural network* (FFNN) merupakan salah satu bentuk arsitektur NN yang secara umum paling banyak digunakan dalam aplikasi di bidang teknik atau rekayasa. Biasanya, aplikasi NN untuk pemodelan runtun waktu dan *signal processing* adalah berdasarkan pada arsitektur MLP atau FFNN. MLP dapat dipandang sebagai suatu kelas yang fleksibel dari fungsi-fungsi *nonlinear*. Secara umum, model ini bekerja dengan menerima suatu vektor dari *input-input* Y dan kemudian menghitung suatu respon atau *output* Z(Y) dengan memproses (*propagating*) Y melalui elemen-elemen proses yang saling terkait. Elemen-elemen proses tersusun dalam beberapa lapis (*layer*) dan data, Y, mengalir dari satu lapis ke lapis berikutnya secara berurutan. Dalam tiap-tiap lapis, *input-input* ditransformasi ke dalam lapis secara *nonlinear* oleh elemen-elemen proses dan kemudian diproses maju ke lapis

berikutnya. Akhirnya, nilai-nilai *output* $Z(Y)$, yang dapat berupa nilai-nilai skalar atau vektor, dihitung pada lapis *output*.



Gambar 1. Arsitektur AR-NN dengan satu lapis tersembunyi, tiga lag variabel dependen sebagai unit input, empat unit neuron di lapis tersembunyi dan satu unit output dengan fungsi aktivasi linear pada lapisan output

Model NN seperti pada gambar 1. di atas adalah contoh bentuk khusus MLP dengan satu lapis tersembunyi (*hidden layer*) yang lebih dikenal dengan FFNN dengan satu lapis tersembunyi. Dalam contoh ini, FFNN terdiri dari tiga *input* (yaitu Y_1 , Y_2 dan Y_3), empat unit *neuron* di lapis tersembunyi dengan fungsi aktivasi ψ , dan satu unit *output* dengan fungsi aktivasi *linear*.

Langkah-langkah dalam pelatihan jaringan *feedforward neural network* adalah sebagai berikut.

- Langkah 0 : Inisialisasi bobot-bobot (tetapkan dalam nilai acak kecil).
- Langkah 1 : Bila syarat dipenuhi, kerjakan langkah 2 sampai 5.
- Langkah 2 : Untuk setiap pasangan pelatihan, kerjakan langkah 3 – 5.
- Langkah 3 : Tiap untuk masukan ($y_i, i = 1, \dots, n$) menerima isyarat menerima isyarat masukan y_i dan diteruskan ke unit-unit tersembunyi.
- Langkah 4 : Tiap unit tersembunyi ($\psi_i, i = 1, \dots, p$) menjumlahkan isyarat masukan terbobot, menggunakan rumus $\psi_{in_jk} = \gamma_{0j} + \sum_{i=1}^n y_i \gamma_{ij}$, dengan menerapkan fungsi aktifasi hitung $\psi_j = f(\psi - in_j)$ dan selanjutnya mengirimkan isyarat ini ke unit-unit keluaran.
- Langkah 5 : Tiap unit keluaran ($\hat{y}_k, k = 1, \dots, m$) menjumlahkan isyarat masukan terbobot dalam bentuk $\hat{y}_{in_k} = \beta_{0k} + \sum_{j=1}^p \psi_j \beta_{jk}$ dengan menerapkan fungsi aktifasi hitung $\hat{y}_j = f(\hat{y}_{in_k})$.

Pada model ini, nilai-nilai respon atau *output* \hat{Y}_t secara umum dapat dihitung dengan menggunakan persamaan berikut.

$$\hat{Y}_{(t)} = \psi^0 \left[\sum_{j=1}^q [\beta_j \psi_j (\sum_{i=1}^p \gamma_{ji} y_{i(t)} + \gamma_{j0}) + \beta_0] \right] \quad (4.1)$$

dengan:

\hat{Y}_t : nilai dugaan dari variabel output

$y_{i(t)}$: variabel input sebanyak p , ($i=1,2,\dots, p$)

γ_{ji} : bobot dari input ke- i yang menuju neuron ke- j pada lapisan tersembunyi, ($j=1,2,\dots,q$)

t : indeks pasangan data input-target ($y_{i(t)}, \hat{Y}_{(t)}$), $t = 1,2, \dots, n$

γ_{j0} : nilai bias pada neuron ke- j pada lapisan tersembunyi $j = 1,2, \dots, q$

β_j : bobot dari neuron ke- j di lapis tersembunyi yang menuju neuron pada lapis *output*

ψ_j : fungsi aktivasi di *neuron* ke- j pada lapis tersembunyi

β_0 : nilai bias pada *neuron* di lapis *output*

ψ^0 : fungsi aktivasi pada *neuron* di lapis *output*

Bentuk *nonlinear* dari fungsi \hat{Y}_t terjadi melalui suatu fungsi yang disebut fungsi aktivasi ψ , yang biasanya fungsi yang halus atau *smooth* seperti fungsi logistik sigmoid yang dituliskan dalam bentuk berikut.

$$\psi(Z) = \frac{1}{1+e^{-Z}} \quad (2)$$

Sedangkan fungsi aktivasi yang berbentuk fungsi sigmoid bipolar yang berbentuk

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3)$$

Dengan nilai turunannya adalah

$$f'(x) = \frac{\sigma}{2} [1 + f(x)][1 - f(x)] \quad (4)$$

Fungsi ini sangat dekat dengan fungsi hiperbolik tangen. Keduanya memiliki range antara -1 sampai 1. Menurut Demut (1998) fungsi hiperbolik tangen atau tansig, di rumuskan sebagai berikut.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \text{ atau } f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (4.5)$$

Dengan nilai turunannya adalah

$$f'(x) = [1 + f(x)][1 - f(x)] \quad (6)$$

Beberapa notasi yang akan digunakan untuk memperjelas beberapa penjabaran proses baik di *input* ataupun *output* pada gambar 4.3 di atas. Bentuk v_j menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot-bobot (bias termasuk di dalamnya) pada lapis tersembunyi di *neuron* ke- j , yaitu

$$v_j = \sum_{i=1}^p \gamma_{ji} y_i + \gamma_{j0}, \quad (7)$$

atau untuk data ke t diperoleh

$$v_{j(t)} = \sum_{i=1}^p \gamma_{ji} y_{i(t)} + \gamma_{j0}. \quad (8)$$

Output pada lapis tersembunyi yang terproses di *neuron* ke- j adalah

$$a_j = \psi_j(v_j), \quad (9)$$

atau untuk data ke t diperoleh

$$a_{j(t)} = \psi_j(v_{j(t)}) = \psi_j\left(\sum_{i=1}^p \gamma_{ji}y_i + \gamma_{j0}\right). \quad (10)$$

Dengan cara yang sama, maka beberapa notasi yang menyatakan penjumlahan *input* dan bobot-bobot pada lapis *output* dapat dinyatakan dalam bentuk berikut.

$$v^o = \sum_{j=1}^q \beta_j a_j + \beta_0, \quad (11)$$

Output pada pada model di atas adalah

$$\hat{y}_{(t)} = a_{(t)}^o = \psi^o(v_{(t)}^o). \quad (12)$$

Dengan demikian, hubungan antara *input* $y_{i(k)}$, $i = 1, 2, \dots, p$ dan $t = 1, 2, \dots, n$, dengan *output* $\hat{y}_{(t)}$ adalah

$$\begin{aligned} \hat{y}_{(t)} &= \psi^o\left(\sum_{j=1}^q \beta_j \psi_j(v_{j(t)}) + \beta_0\right) \\ &= \psi^o\left[\sum_{j=1}^q \left[\beta_j \psi_j\left(\sum_{i=1}^p \gamma_{ji}y_{i(t)} + \gamma_{j0}\right) + \beta_0\right]\right] \\ &= \Psi(y_{1(t)}, y_{2(t)}, \dots, y_{p(t)}) \end{aligned} \quad (13)$$

Pemetaan secara keseluruhan yang terjadi pada FFNN ini selanjutnya dapat ditulis dalam bentuk

$$\begin{bmatrix} \hat{y}_{(1)} \\ \hat{y}_{(2)} \\ \vdots \\ \hat{y}_{(n)} \end{bmatrix} = \begin{bmatrix} \Psi(x_{1(1)}, x_{2(1)}, \dots, x_{p(1)}) \\ \Psi(x_{1(2)}, x_{2(2)}, \dots, x_{p(2)}) \\ \vdots \\ \Psi(x_{1(n)}, x_{2(n)}, \dots, x_{p(n)}) \end{bmatrix} \quad (14)$$

Pemilihan bentuk MLP dengan satu lapis tersembunyi dan fungsi *linear* pada lapis *output* (tidak ada fungsi aktivasi *nonlinear* pada lapis *output*) ini dimotivasi dari fakta yang menyatakan bahwa bentuk ini dapat memberikan pendekatan sebarang yang akurat pada sebarang fungsi dalam berbagai ruang fungsi norm jika dimensi dari ruang bobot adalah cukup besar (Cybenko, 1989; Funahashi, 1989; Hornik dkk., 1989).

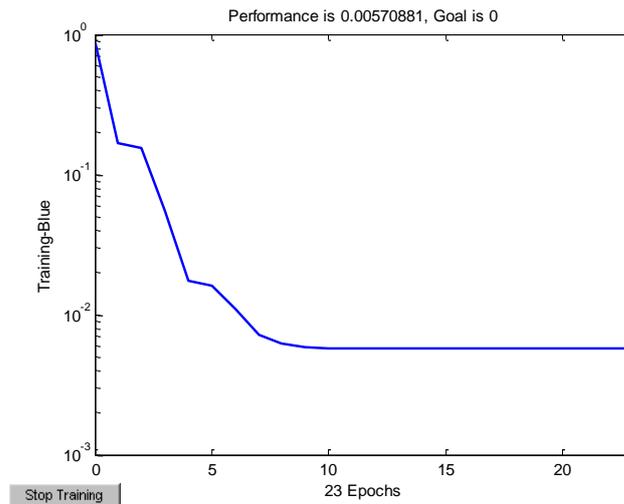
Setelah dilakukan analisis dari hasil penelitian diperoleh bahwa hasil keluaran (target) yang diinginkan berupa produktivitas pegawai UNNES yang terbagi menjadi 2 pola, yaitu produktivitas buruk (0) dan produktivitas baik (1). Pola taksir antara 0,001 sampai dengan 0,499 dan pola taksiran antara 0,500 sampai dengan 1,000.

Melalui identifikasi model juga diperoleh model FFNN (24,3,1) dengan menggunakan 3 *unit hidden* dan 1 *unit output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,0418204 dengan nilai *gradientnya* $0,48871 \times 10^{-5}$. Sedangkan model lain yang didapatkan melalui metode identifikasi model adalah model FFNN (24,4,1). Pelatihan dengan model model FFNN (24,4,1) dengan menggunakan 4 *unit hidden* dan 1 *unit output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,0239869 dengan nilai *gradientnya* $1,31178 \times 10^{-5}$.

Model selanjutnya yang diperoleh adalah model FFNN (24,5,1), pelatihan dengan model FFNN (24,5,1) dengan menggunakan 4 *unit hidden* dan 1 *unit output* dan metode

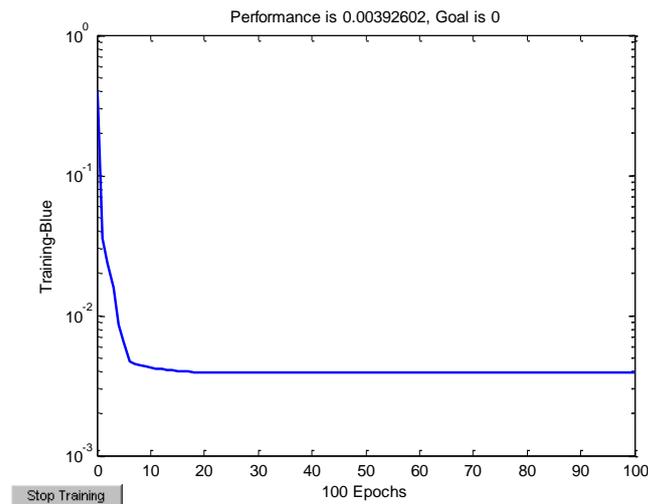
optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,0276539 dengan nilai *gradientnya* $0,34653 \times 10^{-5}$. Pelatihan dengan model FFNN (24,6,1) dengan menggunakan 6 unit *hidden* dan 1 unit *output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,01978 dengan nilai *gradientnya* $0,37509 \times 10^{-5}$.

Model lain yang didapatkan dari langkah identifikasi adalah model FFNN (24,7,1). Pelatihan dengan model FFNN (24,7,1) menggunakan 7 unit *hidden* dan 1 unit *output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,0165623 dengan nilai *gradientnya* $0,54130 \times 10^{-5}$. Secara lengkap, hasil iterasi pelatihan FFNN dengan data *differensi* 24 pada rentang [1,1] masing-masing model dapat dilihat pada lampiran. Hasil pelatihan dengan menggunakan FFNN pada data *differensi* pada rentang [-1,1], beberapa model FFNN juga dikembangkan, dengan identifikasi model diperoleh beberapa model antara lain: model FFNN (24,1,1) dengan menggunakan 1 unit *hidden* dan 1 unit *output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 21 model ini memberikan nilai MSE sebesar 0,00570881 dengan nilai *gradientnya* $0,23376 \times 10^{-5}$. Terlihat bahwa pada *epoch* ke 23 model ini mencapai kekonvergenan dengan menuju nilai tertentu. Hasil iterasinya ditunjukkan pada gambar berikut.



Gambar 2. Hasil pelatihan dengan menggunakan model FFNN (24,5,1)

Pelatihan dengan model FFNN (24,5,1) dengan menggunakan 5 unit *hidden* dan 1 unit *output* dan metode optimasi yang digunakan dalam pelatihan adalah Levenberg Marquat, diperoleh hasil pada *epoch* ke 100 model ini memberikan nilai MSE sebesar 0,0392602 dengan nilai *gradientnya* $2,11941 \times 10^{-5}$. Model ini menghasilkan *epoch* ke 100 untuk mencapai konvergen. Hasil iterasinya ditunjukkan pada gambar berikut.



Gambar 3. Hasil pelatihan dengan menggunakan model FFNN (24,7,1)

Dalam penelitian ini untuk menghasilkan iterasi tercepat, nilai-nilai dari jumlah lapisan tersembunyi dan konstanta belajar diubah-ubah. Perubahan dilakukan dengan memberi nilai tetap pada salah satu item. Hasil penelitian ini menunjukkan bahwa data-data yang dikumpulkan melalui kuesioner kemudian diberikan pelatihan dan diuji menunjukkan bahwa faktor pengetahuan, keahlian, kemampuan sikap dan perilaku yang baik tidak selalu menunjukkan produktivitas yang baik. Namun demikian ada dua faktor yang cukup dominan dalam mempengaruhi ketercapaian tahun reputasi di FMIPA UNNES tahun 2017 yaitu faktor pengetahuan dan perilaku.

SIMPULAN

Berdasarkan hasil penelitian dan pembahasan, diperoleh simpulan: (1) produktivitas kinerja dosen dan tenaga kependidikan dalam mewujudkan tahun reputasi Universitas Negeri Semarang (UNNES) menggunakan jaringan saraf tiruan bahwa hasil penelitian ini menunjukkan bahwa faktor pengetahuan, keahlian, kemampuan sikap dan perilaku yang baik tidak selalu menunjukkan produktivitas yang baik, (2) faktor-faktor yang sangat berpengaruh dalam produktivitas kinerja dosen dan tenaga kependidikan dalam mewujudkan tahun reputasi Universitas Negeri Semarang yaitu faktor pengetahuan dan perilaku.

DAFTAR PUSTAKA

- Bishop, C.M. (1995). *Neural Network for Pattern Recognition*. Oxford, Clarendon Press.
- Chen, J., dan Chaudhari, N.: Protein Secondary Structure Prediction with bidirectional LSTM networks. In: *International Joint Conference on Neural Networks: Post conference Workshop on Computational Intelligence Approaches for the Analysis of Bio-data (CI-BIO)*, (205).
- Fine, T.L. (1999). *Feedforward Neural Network Methodology*. Springer, New York.
- Gers F.A., Schmidhuber, J (2001). LSTM Recurrent Networks Learn Simple Context Free and Context Sensitive Languages. *IEEE Transactions on Neural Network* 12 (6), 1333-1340.

- Hoptroff (1993). : Framewise Phoneme Classification with Bidirectional LSTM Networks and Other Neural Network Architectures. *Neural Networks* 18 (5-6), 602-610 (2005b)
- Hawkins, D.M. (1980). *Identification of Outlier*. London: Chapman and Hall
- Haykin, H. (1999). *Neural Networks: A Comprehensive Foundation*, 2nd edition. Prentice-Hall, Oxford.
- Hochreiter, S., Bengio, Y., Frasconi, P., Schmidhuber, J. (2001b) Gradient flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies. In: Kremer, S.C., Kolen, J.F. (eds) *A Filed Guide to Dynamical Recurrent Neural Networks*, IEEE Press
- Husen, W. (2001). Forecasting of Maximum Short Term Electricity Consumption by Using Elman-Recurrent Neural Network, *Unpublished Final Project*, Department of Physics Engineering, Institut Teknologi Sepuluh Nopember, Indonesia.
- Kaashoek, J.F. and Van Dijk, H.K., (2001). Neural Networks as Econometric Tool. *Report EI 2001-05*, Econometric Institute Erasmus University Rotterdam.
- Lawrance dan Balakrishma, N. (2001). Statistical aspects of chaotic maps with negative dependence in communication setting. *Journal of the Royal Statistical Society*, B 63, 843-853.
- Menezes, L.M. & McSharry, P.E. (2006). A comparison of univariate methods for forecasting electricity demand up to a day ahead. *International Journal of Forecasting*, 22, 1-16.
- Park, K, and Willinger W. (2000) (eds) *Self-similar network traffic and performance evaluation*, John Wiley & Sons, New York.
- Ripley, B.D. (1996). *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge.
- Ristiana, Y. 2008. Autoregressive Neural Network Model (ARNN) for Forecasting Short Term Electricity Consumption at PT. PLN Gresik. Unpublished Final Project, Department of Physics Engineering, Institut Teknologi Sepuluh Nopember, Indonesia.
- Swanson dan White, H. (1995). Learning in Artificial Neural Networks: A statistical Perspective. *Neural Computation*, Vol. 1, pp. 425-464.
- Taylor J.W. (2003). Short-term electricity demand forecasting using double seasonal exponential smoothing. *Journal of the Operational Research Society*, 54, 799-805
- Walid, Subanar, Dedi. R., Suhartono (2012). Recurrent Neural Network (RNN) pada Beban Listrik di Semarang. *Prosiding Seminar Nasional Matematika*. Unnes.
- Walid dkk (2015). Fractional Integrated Recurrent Neural Network (FIRNN) for Forecasting of Time Series Data with Applications in Electric Load in Java-Bali. *Contemporary Engineering Sciences*, Vol. 8, 2015, no. 31, 1485 - 1500