

УДК 656.259.1

ПАНЧЕНКО С. В., д-р техн. наук, профессор (Український державний університет залізничного транспорту)

САЯПИНА І. А., старший преподаватель (Государственный экономико-технологический университет транспорта)

Нейросетевая модель устройства управления помехоустойчивой тональной рельсовой цепью

Разработана нейросетевая модель устройства управления тональной рельсовой цепью, позволяющая повысить её помехоустойчивость за счет более точной подстройки защитного временного интервала, в течение которого на вход путевого приемника не поступают помехи. Способность адаптировать длительность задержки сигнала к условиям работы рельсовой цепи достигается благодаря использованию в составе модели нейронных сетей, нейроны которых подстраивают при этом свои синаптические веса.

Ключевые слова: нейрон, нейронная сеть, весовые коэффициенты, моделирование, тональная рельсовая цепь, рельсовая линия.

Введение

Работа автоматизированных систем управления движением поездов, отвечающих за безопасность и эффективность перевозочного процесса, в значительной степени зависит от исправной работы первичных элементов контроля свободности блок-участков и целостности рельсовых нитей. В качестве таких элементов широко распространение на железных дорогах Украины получили тональные рельсовые цепи (ТРЦ). Электрификация железных дорог, внедрение новых типов электроподвижного состава, увеличение интенсивности движения ставит новые требования перед существующими системами железнодорожной автоматики. Поэтому актуальным становится вопрос их совершенствования и модернизации.

Постановка задачи и анализ исследований

В работе поставлена задача создания нейросетевой модели помехоустойчивой ТРЦ. Для ее реализации использована среда программирования Matlab, в частности пакет расширения Neural Network Toolbox, содержащий средства для проектирования, моделирования, разработки и визуализации нейронных сетей. Основные принципы построения нейронных сетей представлены в работе [1]. В материалах работы [2] описана структурная схема помехоустойчивой ТРЦ. В статье [3] рассмотрены существующие методы и средства нейросетевого моделирования аппаратуры рельсовых цепей.

Основной материал

Нейросетевая модель, реализованная в программном приложении Simulink, состоит из пяти нейронных сетей, каждая из которых адаптирует величину задержки для сигнала с соответствующей несущей частотой. Вид программной реализации для одной нейронной сети показан на рис. 1.

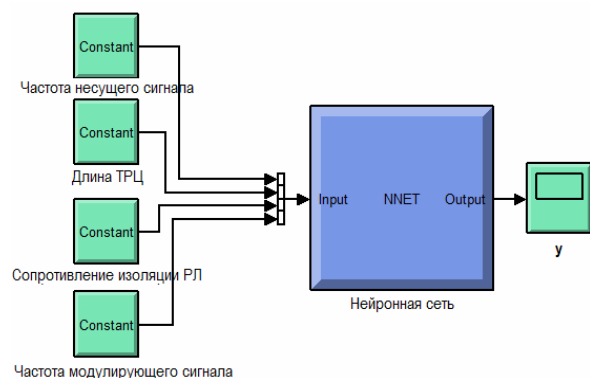


Рис. 1. Вид элемента нейросетевой модели

На рис. 1 блоки "Constant" используются для задания пользователем исходных параметров: частоты несущего сигнала, длины ТРЦ, сопротивления изоляции рельсовой линии и частоты модулирующего сигнала. Эти данные объединяются в вектор, который и является входным вектором для нейронной сети. На ее выход "y" выводится значение задержки для заданных параметров сигнала. Все нейронные сети имеют идентичную структуру. Более подробная структура блока нейронной сети представлена на рис. 2. Далее рассмотрено назначение его составляющих элементов.




Рис. 2. Структура блока Neural Network

Блок "Input" являється входним для поступлення даних в підсистему, які далі в блоці "Process Input 1" перетворюються в формат, необхідний для роботи нейронів прихованого шару "Layer 1". "Process Input 1" виконує три операції:

- "Fixunknowns" представляє матриці входних даних, що містять NaN значення (виникають при діленні нуля на нуль, нескінченності на нескінченність і т. п.) в вигляді, необхідному для обробки в Simulink;
- "Removeconstantrows" перетворює матрицю даних, видаляючи стовпці з постійними значеннями;
- "Marpminmax" приводить значення мінімуму і максимуму кожного стовпця матриці даних до [-1, 1], тобто перетворює даний вектор в колінеарний вектор, але одиничної довжини.

Підсистема нейронів прихованого шару НС (рис. 3) складається з одного входу з вектором $p\{1\}$, лінії затримки "Delays 1", блоку ваг "W", блоку ваг зсувів "b", блоку сумування "Netsum", блоку функції активації "tansig", вихода першого шару мережі з іменем $a\{1\}$.




Рис. 3. Структура прихованого шару нейронної мережі "Layer 1"

Масив входних даних $p\{1\}$ подається на лінію затримки "Delays 1" (рис. 4), призначену для затримки входних сигналів, що дозволяє розширити можливості нейромоделі.



Рис. 4. Структура блоку "Delays 1"

Блок "mux" мультиплексує сигнали $p\{1\}$, що приходять з входного шару, тобто перетворює множину векторів в один вектор загальної довжини $pd\{1\}$.

Блок ваг "W" містить масив з матрицями ваг входів нейронів прихованого шару $IW\{1,1\}$ (рис. 5). Кількість нейронів в прихованому шарі в усіх НС однакова і становить 15.

На рис. 5 блоки "Weights" містять інформацію про вагові коефіцієнти відповідного нейрона, а блок "dotprod" виконує взвешування сигналу. Взвешені сигнали поступають на входи "Mux", який для першого шару не формує вектор сумарної довжини, ввиду наявності другого шару нейронів, аналогічний блок якого виконує цю функцію.




Рис. 5. Структура блоку ваг "W"

Блок весов смещений "b" (рис. 3) позволяет ускорить процесс обучения. Массив весов смещений $b\{1\}$ заранее не известен и определяется в процессе обучения. Блок "netsum" вычисляет сумму компонентов каждого нейрона, учитывая также и смещение. Полученная сумма поступает в блок функции активации гиперболического тангенса "tansig", а результат $a\{1\}$ – на вход следующего слоя нейронов.

Структура второго выходного слоя нейронов "Layer 2" (рис. 2) аналогична "Layer 1" и представлена на рис. 6.




Рис. 6. Структура выходного слоя нейросети "Layer 2"

Единственное отличие заключается в том, что этот слой составляет один нейрон с линейной активационной функцией. Поэтому блок весов "W" для этого слоя нейросетевой модели будет содержать лишь один элемент "Weights" и "dotprod" (рис. 7).

Результат линейного преобразования активационной функции подается на выход второго слоя $a\{2\}$, преобразуется в "Process Output 1" и поступает на выход нейросети (рис. 2).




Рис. 7. Структура блока весов "W" для второго слоя

Блок "Process Output 1" (рис. 2) является выходным блоком и выполняет преобразование данных в их изначальный формат, обратное "Process Input 1". В состав "Process Output 1" входят две функции:

- "Mapminmaxreverse" приводит значение минимума и максимума каждого столбца матрицы данных от [-1, 1] к его первоначальному;
- "Removeconstantrowsreverse" возвращает обратно столбцы с постоянными величинами там, где они были ранее удалены.

В качестве примера моделирования работы предложенного метода на вход нейросетевой модели подавался сигнал, содержащий информацию о частоте несущего сигнала $f_n=420$ Гц, длине ТРЦ $\ell=1$ км, значении сопротивления изоляции $R=1$ Ом, температуре окружающей среды $T=20^\circ C$. Массивы данных на выходе элементов соответствующей НС указаны в табл. 1.

Таблица 1

Значения на выходе элементов нейронной сети

Input	Process Input	Layer 1	Layer 2	Process Output
$\begin{vmatrix} 420 \\ 1 \\ 1 \\ 8 \end{vmatrix}$	$\begin{vmatrix} 1 \\ -0,9647 \\ 0,5 \end{vmatrix}$	-0,9999	0,775	0,8752
		0,9977		
		0,6877		
		-0,4984		
		-0,3626		
		-0,9989		
		-0,996		
		0,8871		
		-0,9216		
		0,9951		
		-0,9877		
		0,7558		
		-1		
		-1		
-1				

Входной сигнал содержит четыре величины, должно быть связано четыре входа, однако в блоке соответственно с каждым нейроном скрытого слоя "Process Input 1" (рис. 2) функция

"Removeconstantrows" убирає стовпці повторюючихся значень частоти, поэтому в колонке весових коефіцієнтів даного слоя указано по три значення.

Пятая нейросеть, адаптирующая величину задержки для сигнала с несущей частотой 720 Гц, отличается от других тем, что в ее скрытом слое содержатся не 15, а 20 нейронов и ее обучение проводилось с помощью Байесовской регуляризации "Bayesian Regulation". Для подстройки весов и смещений используется алгоритм Левенберга-Марквардта [4-7]. Использование алгоритма Гаусса-Ньютона для аппроксимации вычисления гессиана позволяет уменьшить количество расчетов. Данный метод минимизирует комбинацию квадратов ошибок и весов для получения наилучших обобщающих свойств нейросети. Он позволяет найти такой вектор весовых коэффициентов, при котором реализуемая с помощью нейронной сети зависимость будет иметь более гладкий вид. Это свойство также помогает избавиться от проблемы высокой точности аппроксимации в экспериментальных точках и в то же время большой ошибки в промежуточных точках при структурной избыточности сети. Регуляризованная целевая функция принимает вид [7]:

$$F(\mathbf{w}) = \beta E_D + \alpha E_w, \quad (1)$$

где E_D – сумма среднеквадратичных ошибок сети;

E_w – сумма квадратов весов сети;

α и β – параметры целевой функции.

Соотношение α и β определяет акцент при обучении: при $\alpha \ll \beta$ обучающий алгоритм направлен на минимизацию ошибки, а при $\alpha \gg \beta$ – на уменьшение весов. При этом происходит увеличение ошибки и отклик сети приобретает сглаженную форму.

Перед началом работы алгоритма осуществляется инициализация весов сети и параметров α и β . Далее для минимизации целевой функции (1) рассчитывается один шаг алгоритма Левенберга-Марквардта. Вычисляется эффективное число параметров [7]:

$$\gamma = N - 2\alpha \text{tr}(\mathbf{H})^{-1}, \quad (2)$$

где N – общее число параметров сети,

\mathbf{H} – матрица Гессе, которая в соответствии с аппроксимацией Гаусса-Ньютона рассчитывается [7]:

$$\mathbf{H} = \nabla^2 F(\mathbf{w}) \approx 2\beta \mathbf{J}^T \mathbf{J} + 2\alpha \mathbf{I}_N, \quad (3)$$

где \mathbf{J} – якобиан ошибок на обучающей выборке.

На следующем шаге рассчитываются новые оценки параметров целевой функции [7]:

$$\alpha = \frac{\gamma}{2E_w(\mathbf{w})}, \quad (4)$$

$$\beta = \frac{n - \gamma}{2E_D(\mathbf{w})}. \quad (5)$$

Описанные шаги повторяются до тех пор, пока не выполнится любое из условий:

1) количество повторов алгоритма достигнет максимального значения;

2) параметр времени превысит установленный максимум;

3) эффективность примет заданное значение;

4) градиент эффективности станет меньше заданной величины min_grad .

Процесс обучения нейросети был завершен при значении среднеквадратической ошибки $1,74 \cdot 10^{-4}$. Графики изменения градиента, μ , эффективного числа параметров и суммы квадратов весов сети представлены на рис. 8, графики значения регрессии – на рис. 9.

Чтоб оценить, насколько нейросетевая модель адаптивного устройства повышения помехоустойчивости позволяет повысить точность подстройки защитного временного интервала при одинаковой частоте модуляции сигнала, предположим, что при отсутствии свойства адаптивности устройство использовало бы среднее значение задержки. С помощью программы Microsoft Excel определено среднее значение задержки 0,4565 мс, среднее квадратическое отклонение 0,1453 мс и дисперсия 0,0211 мс². Максимальное и минимальное значение задержки сигнала составляет соответственно $t_{3 \max} = 0,9269$ мс и $t_{3 \min} = 0,2464$ мс. Следовательно, с учетом погрешности обучения $2 \cdot 10^{-4}$ модель адаптивной линии задержки позволяет повысить точность подстройки временного интервала до

$$t = t_{3 \max} - t_{cp} - t_{погр}, \quad (6)$$

$$t = 0,9269 - 0,4565 - 0,0002 = 0,4702 \text{ мс}.$$

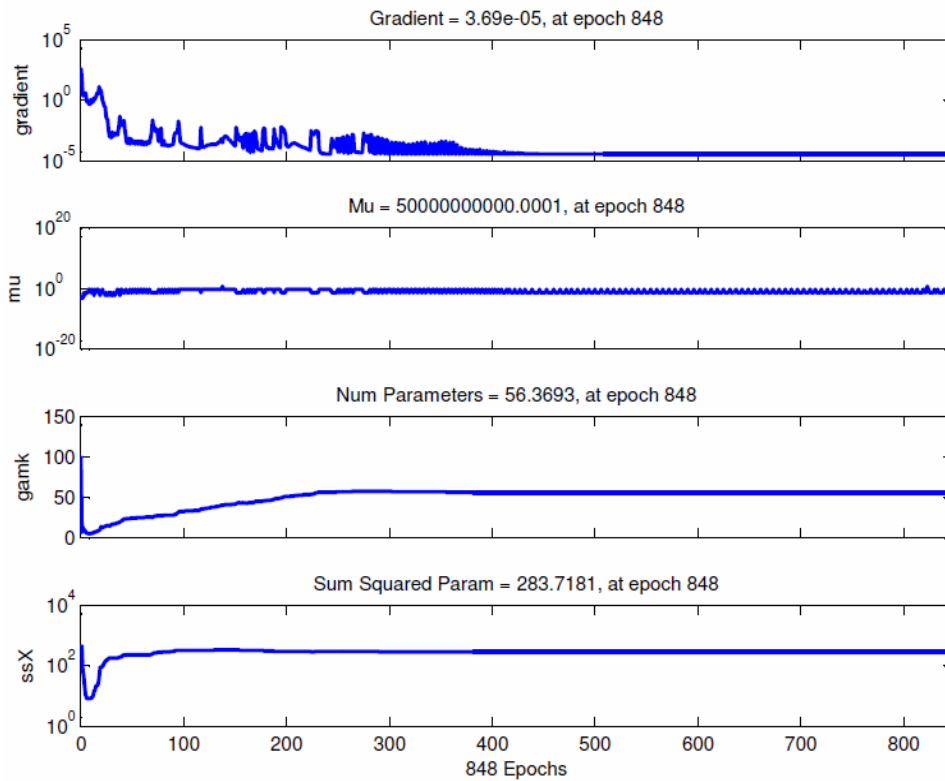


Рис. 8. Графики изменения градиента, μ , эффективного числа параметров и суммы квадратов весов сети

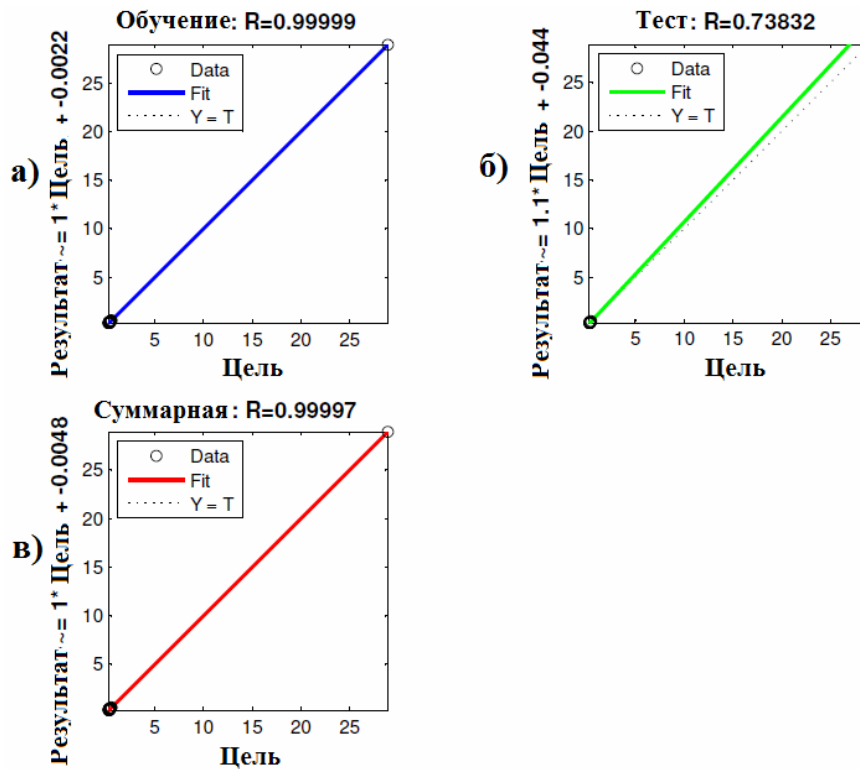


Рис. 9. Значение регрессии при обучении (а), тестировании модели (б) и суммарная регрессия (в)

Выводы

Описанная модель дает возможность спрогнозировать величину задержки сигнала, поступающего на вход путевого приемника при заданных параметрах длины рельсовой линии, сопротивления изоляции, частоты несущего сигнала и частоты модуляции ТРЦ.

Список использованных источников

1. Хайкин, С. Нейронные сети: полный курс [Текст] / С. Хайкин. – [2-е изд., испр.]. – М.: ООО «И.Д. Вильямс», 2006. – 1104 с.
2. Рельсове коло [Текст]: пат. 101093 України МПК В 61 L 23/00 / Бабаєв М.М., Кошевий С.В., Сотник В.О., Романчук В.Б., Ананьєва О.М., Саяпіна І.О.; власник Українська державна академія залізничного транспорту. – № а 2011 10949; заявл. 13.09.2011; опубл. 25.02.2013, Бюл. № 4. – 5 с.
3. Саяпина, И. А. Нейросетевая модель устройства повышения помехоустойчивости рельсовой цепи [Текст] / И.А. Саяпина // Інформаційно-керуючі системи на залізничному транспорті: наук.-техн. журнал. – Харків: УкрДАЗТ, 2014. – Вип. 3(106). – С.44-48.
4. Vapnik, V.N. The nature of statistical learning theory [Text]: 2nd edition / V.N. Vapnik. – New-York: Springer-Verlag, 2000. – 319 p.
5. Levenberg, K. A. Method for the Solution of Certain Problems in Least Squares [Text] / K.A. Levenberg // Quarterly of Applied Mathematics.– USA: Brown University, 1944. – Vol. 2. – P. 164–168.
6. Ranganathan, A. The Levenberg-Marquardt Algorithm [Text] / A. Ranganathan // Tutorial on LM Algorithm, 2004. – P. 1-5.
7. Foresee F.D., Hagan M.T. Gauss-Newton Approximation To Bayesian Learning [Text] / F.D. Foresee // Proceedings of the International Joint Conference on Neural Networks. – San Jose CA: Institute of Electrical and Electronics Engineers, 1997. – P. 1930-1935.

С. В. Панченко, І. О. Саяпіна. Нейромережева модель пристрою керування завадостійким рейковим колом. Розроблено нейромережеву модель пристрою керування тональним рейковим колом, що дає змогу підвищити його завадостійкість за рахунок більш точного підстроювання захисного часового інтервалу, протягом якого на вхід колійного приймача не надходять завади. Здатність адаптувати тривалість затримки сигналу до умов роботи рейкового кола досягається завдяки використанню в складі моделі нейронних мереж, нейрони яких підлаштовують при цьому свої синаптичні ваги.

Ключові слова: нейрон, нейронна мережа, вагові коефіцієнти, моделювання, тональне рейкове коло, рейкова лінія.

S. V. Panchenko, I. A. Saiapina. Neural network model of the control unit for noise-immune tonal track circuit.

The article deals with a designed neuronet model of the control unit for an audio frequency track circuit which makes it possible to increase its noise stability by using the fine tuning of a guard time during which track receivers do not receive disturbances. It can adapt long signal delays to the track circuit operating conditions by using neuronets integrated in the model, the neurons adjusting their synaptic weights. The division of the neuronet model into five functional components which depend on the frequency of the carrying signal allowed minimizing the root-mean-square error for a learning sample, and also reducing the number of neurons in a buried layer of the neuronet.

Keywords: neuron, neuronet, weight coefficients, modelling, tone track circuit, rail line.

Стаття надійшла 30.01.2017 р.

Панченко С. В., доктор технічних наук, професор, ректор Українського державного університету залізничного транспорту, Харків, Україна. E-mail: eltech@kart.edu.ua

Саяпіна І. А., старший преподаватель кафедри "Телекомунікаційні технології і автоматика" Державного економіко-технологічного університету транспорту, Київ, Україна E-mail: inna.saiapina@gmail.com

Panchenko S. V., Doctor of Engineering, professor, rector of the Ukrainian State University of Railway Transport, Kharkiv, Ukraine. E-mail: eltech@kart.edu.ua

Saiapina I. A., Senior Lecturer of "Telecommunication technology and automation" department of State Economy and Technology University of Transport, Kiev, Ukraine. E-mail: inna.saiapina@gmail.com.