

Dariusz AMPUŁA

*Military Institute of Armament Technology (Wojtkowy Instytut Techniczny Uzbrojenia)*

## NEURAL NETWORKS FOR TESTED MG ARTILLERY FUSES

### Sieci neuronowe dla badanych zapalników artyleryjskich typu MG

**Abstract:** *The article presents the information about the usage of artificial neural networks. The automation process of neural networks of the analysed evaluation data results is highlighted. The kinds of MG type artillery fuses are described and the kinds of cartridges' calibres, in which they are used, are also specified. The way of preparation of databases of test results to computer simulation is described. Building of neural networks determining the main technical parameters and sizes of learning, test and validation sets is characterized. The summary for chosen active neural networks for individual kinds of the analysed MG type artillery fuses is presented. Graphs of learning, values of sensibility indicators and fragments of prediction sheets for the chosen neural networks were shown.*

**Keywords:** neural networks, artillery fuse, neuron, hidden layer, laboratory tests, evaluation module, importance classes.

**Streszczenie:** *W artykule przedstawiono informację dotyczącą kierunków zastosowania sztucznych sieci neuronowych. Podkreślono fakt automatyzacji przez sieci neuronowe procesów ocenowych analizowanych wyników danych. Opisano rodzaje zapalników artyleryjskich typu MG, określono również rodzaje kalibrów nabojów w których są one stosowane. Opisano sposób przygotowania baz wyników badań do symulacji komputerowych. Scharakteryzowano budowane sieci neuronowe, określając ich główne parametry techniczne oraz wielkości zbiorów uczącego, testowego i walidacyjnego. Przedstawiono podsumowania dla wybranych aktywnych sieci neuronowych dla poszczególnych rodzajów analizowanych zapalników artyleryjskich typu MG. Pokazano wykresy uczenia, wartości wskaźników wrażliwości oraz fragmenty arkuszy predykcji dla wybranych sieci neuronowych.*

**Słowa kluczowe:** sieci neuronowe, zapalnik artyleryjski, neuron, warstwa ukryta, badania laboratoryjne, moduł ocenowy, klasy ważności.

## **1. Introduction**

The 80s of the last century was a period of dynamic development for the new field of science, which was the theory of artificial neural networks. Neural networks can be applied everywhere where problems related to creation of mathematical models appear, such as automatically permitting to map in computer different complex dependences on input signals and chosen output signals. The adjustment of neural networks to specific analytical problem takes places through the selection of variable parameters of network, so that behaviour of the designed model matches (in the definite sense) with the real system operation.

Neural networks according to [2] cause, in certain sense, automation of evaluation processes of the analysed test results when the process of making decision is based on quantitative data with the minimum participation of descriptive data and symptoms expressed in categories of exclusively quantitative. However, an error will be to assume that numerical form of symptoms and other entrance features constitutes a condition of the application of neural networks in the diagnosis. Contrary, there are proofs that contrasted with other computer methods (for example as contrasted with discriminative analysis) by using neural networks, very good results were also obtained applying this technique to diagnose the problems, which are not possible to formalize in the numerical space.

Furthermore, according to [3], artificial neural networks are also applied in the prediction of the determined phenomena and events, thus, they have the ability to predict output data (future events) based on learnt input data, obviously correlated with the corresponding output data. This is the feature which can be used in diagnostic tests of ammunition. That is why an attempt was undertaken to develop such evaluation model based on the obtained empirical results of checks of tested fuses.

The aim of this article was to design and build artificial neural networks for every kind of MG artillery fuses considered in this article. To achieve such purpose MG-25, MG-37 and MG-57 artillery fuses were chosen. There are numerous databases of test results, which gives high probability to construct artificial neural networks with high-quality level of their work.

This article shows the possibility to apply artificial neural networks to support taking post-diagnostic decisions for the tested artillery fuses. The designed neural networks concerned only evaluation modules of the tested fuses in the scope of the first laboratory diagnostic tests.

## **2. Building neural networks for artillery fuses**

The results of diagnostic tests for first laboratory tests MG-25, MG-37 and MG-57 fuses were prepared to designed artificial neural networks.

MG-25 fuses are applied in 23 mm cartridges with high-explosive fragmentation incendiary tracer projectile to anti-aircraft gun and in 25 mm cartridges with high-explosive fragmentation incendiary tracer projectile, MG-37 type fuses are applied in 37 mms cartridges with fragmentation tracer projectile to gun model 39, however, MG-57 type fuses are applied in 57 mm cartridges with fragmentation tracer projectile to S-60 and S-68 guns.

All three kinds of the analysed fuses in article artillery fuses, are head fuses [1], mechanical with the action with short delay with self – destructor without protection. The main elements of these fuses are as follows: primer cap, spring, detonator cap, charge, needle and pyrotechnic mass. Except these main elements, every element has yet several other sub-elements, which are also subject to obligatory checks during first laboratory diagnostic tests.

Laboratory tests of artillery fuses comprise the following fields: hermetic seal of fuses, checking the external surface and surface technical condition, correctness of assembly and state of units and parts, tests correctness of working primer caps and stimulation caps, checking the reliability of fire chain fuses, physical – chemical tests of high explosives belonging to the system of fuses. Laboratory tests of fuses are two – stage tests. In the first laboratory test, we control individual units and parts and check the main parameters of the given type of fuse. The range of the second laboratory test is established depending on the quantity and qualification of inconsistencies, which appeared in the first diagnostic test. Therefore, designing artificial neural networks for second laboratory diagnostic tests will be a somewhat greater problem due to the lack of uniform criteria which were applied to these second diagnostic tests. The author of the article predicts such possibility, however, this will be an object of a separate article.

From the possessed databases of the fuse types considered in the article, test results of the so-called scientific and research inquiries were eliminated, the range of which differs from the remaining standard diagnostic tests. Diagnostic test results prepared for other departments than national defence were not analysed yet. It means that in compliance with the research methodology, test results were analysed, for which test type was one (RB=1), which signifies storage of these test samples of fuses in the subset determined in the methodology tests<sup>1</sup> as “K”. All restrictions of the prepared sets of test results were aimed to create homogeneous sets of test results, which could be analysed while building artificial neural networks for type MG artillery fuses.

Laboratory diagnostic tests of every of these three kinds of fuses consist in testing their properties (features), which, according to the research methodology, were divided into five importance classes (inconsistencies): A, B, C, D and E. Depending on the number of detected inconsistencies in individual importance classes during laboratory tests, a post-diagnostic decision is received, which is compliant with the given evaluation module for a specific MG fuse.

In models of artificial neural networks, only evaluation modules were analysed and it was assumed that all tested features of the given MG fuse and information about the number

---

<sup>1</sup> Methodology of diagnostic studies of ammunition - Index N-5001b – 1985. Archive MIAT.

of fuses inconsistent in the individual importance classes were in our case the input signals (predictors) of the designed neural networks.

These predictors were delivered to build networks in the form of record as numerical mark i.e. if during diagnostic test no inconsistencies of the given importance class were found, then the value zero was delivered. However, in case when tests detected inconsistencies, then a specific number of these inconsistencies in a given importance class was given. The built neural networks for all types of artillery fuses, consisted only of one hidden layer. The output parameters for these designed neural networks were post-diagnostic decisions determined in research methodology. The number of these parameters depends on the number of post-diagnostic decisions, which are possible to take, which were determined in the evaluation module for specific MG type fuse.

Delivered values of predictors will be thus a stimulation of neurons found in hidden layers, where they will be transformed by the determined activation functions of neurons. The values calculated by these functions will ultimately be the output values, that is, output values of these neuron layers. The behaviour of all hidden neurons was strongly dependent on the kind of used activation function. In all built artificial neural networks, four kinds of activation function of hidden layers were assumed: logistic function, exponential function, hyperbolic tangent function (tanh) and linear function.

An important element in designing neural networks is assuming the activation function for output layer. In our case, for all built artificial neural networks, softmax function was adopted as the most suitable for the analysed research problem.

The next matter, which should be determined during designing these neural networks, was the way of joining these neurons with each other. After the analysis of fuses, the so-called one-way *feedforward* neural networks were proposed, because it was found that this type of network mostly fits to the considered research problem.

The application of *peer-to-peer* connections of neurons between individual layers of built models of neural networks allowed to create network called as multilayer perceptron (MLP).

The next problem during designing artificial neural networks was to determine the number of hidden neurons in the hidden layers. Determining these quantities by trial and error can last months, but thanks to the modern computer software [4] we can conduct simulations and determine it more quickly. However, even with this method, searching the most suitable neural network can last weeks, because we have to consider different quantities of hidden neurons and thus, hundreds of we artificial neural networks should be built.

The next step was to determine the values of weight coefficients (synaptic weights) for individual predictors. These values were randomly determined by the software, which, as a result of further calculations and analyses, introduced specific value of weight and corrected it to obtain the highest probability of the calculated values of quality coefficients.

Every neural network had to come an arduous way of the learning process, which is known as an interdeterministic process. There are many methods of learning, but in our

case, the most frequently applied method of backward propagation of errors (*backpropagation*) was adopted.

At the beginning, two data sequences were prepared: learning sequence and testing sequence.

For the simulation of the designed neural networks, 70% of the possessed test results were generated for the learning sequence. Having processed the entire learning sequence (called the epoch), error of epoch was calculated and the entire cycle of building of the given network was repeated to the moment till this error decreased below the permitted level accepted by the network author.

Taught networks were checked by means of testing sequence, to which 15% of the possessed test results were chosen, but these data were previously not used. This sequence served to conduct an independent control of progresses of the adopted learning algorithm.

The last thing which was performed was the validation of built neural networks that is testing network in view of the ability to generalise on the determined validation sequence. Validation sequences generated also 15% of the possessed test results, which were earlier neither introduced to learning sequences nor to testing sequences. The validation of the designed neural networks was the next verification of the correct functioning of the designed artificial neural networks.

### 3. Neural network for MG-25 fuses

Designing artificial neural networks for MG-25 fuses for first diagnostic tests started with the assumption that this network will be one-way MLP network. All neurons in the network will be connected with each other (*peer-to-peer connection*). Initially, sigmoid function was assumed as the activation function of hidden layer and three hidden neurons in this layer. To find the best neural network, next neurons were introduced to the hidden layer, finishing with value of 15 hidden neurons. The following sets were designated: learning, testing and validating in proportions determined above. 200 networks were built for every analysed activation function of hidden layer and for every number of the used hidden neurons in the designed neural networks. Six kinds of the acceptable post-diagnostic decisions were adopted as output signals in compliance with the methodology. The value of inconsistency class A – predictor LA was not considered as predictor, because this variable was not essential statistically.

Summary of active networks (MG25 RB=1)								
Id network	Name of network	Quality (learning)	Quality (testing)	Quality (validation)	Algorithm of learning	Error function	Activation (hidden)	Activation (exit)
83	MLP 7-3-6	93,89313	96,36364	94,54545	BFGS 20	Entropia	Tanh	Softmax

**Fig. 1.** Summary of chosen neural network for first diagnostic tests of MG-25 fuses

As a consequence, different parameters of the designed neural networks were obtained. After an in-depth analysis of these parameters, the best neural network was selected for the first diagnostic tests of MLP 7-3-6, Id of network 83, which main parameters were presented in fig. 1.

The basic parameter which was taken under consideration during the choice of the best neural network, was the obtained quality value of testing for a given network. This parameter determines the accuracy of the built neural network.

In this case, value amounting to 96,36, what is very good result during building neural networks was reached. The next very important factor choice of given built neural network was its topology. During the choice this best designed artificial neural network of course took into consideration next parameters of built neural network which evidently indicated on superiority this network in comparison to other which had somewhat worse indicators.

While building this neural network, a BFGS learning algorithm was applied. We received a value of 20 epoch, by which were presented the quality values presented in the summary. By designing this network, mutual entropy error function and hyperbolic tangent function (tanh) of the hidden layer activation were used. As the activation function of the output layer, the previously mentioned softmax function was used.

ID of weight	Weights of network (MG25 RB=1)	
	Connections 83.MLP 7-3-6	Values of weights 83.MLP 7-3-6
10	NB --> hidden neuron 2	-2,6933
11	N --> hidden neuron 2	-7,0008
12	NC --> hidden neuron 2	-7,7620
13	LC --> hidden neuron 2	-7,8803
14	LE --> hidden neuron 2	-3,4348
15	LA --> hidden neuron 3	0,1065
16	LB --> hidden neuron 3	-0,0770
17	NB --> hidden neuron 3	-0,0172
18	N --> hidden neuron 3	-0,2287
19	NC --> hidden neuron 3	-0,5834
20	LC --> hidden neuron 3	-0,2091
21	LE --> hidden neuron 3	-11,1534
22	dislocation input --> hidden neuron 1	-0,3771
23	dislocation input --> hidden neuron 2	3,9544
24	dislocation input --> hidden neuron 3	-0,0065
25	hidden neuron 1 --> DEC(B3)	-1,0940
26	hidden neuron 2 --> DEC(B3)	-2,6204
27	hidden neuron 3 --> DEC(B3)	4,1884
28	hidden neuron 1 --> DEC(B5)	-8,4479
29	hidden neuron 2 --> DEC(B5)	1,6489
30	hidden neuron 3 --> DEC(B5)	3,9224

Fig. 2. Fragment of weight values for first diagnostic tests of MG-25 fuses

In the learning process in the following iterative steps, the designed network randomly worked out a series of synaptic weights values, which were changed while building connections in the subsequent new neural networks, due to the occurrence of the so-called learning errors. The fragment of the final values of these weight coefficients for our neural network 83.MLP 7-3-6 was presented in fig. 2.

Fig. 3 shows a graph of learning network for a chosen artificial neural network. On this graph you can notice 20 epoch, by which a network finally learnt to correctly find the values of output signals.

Fig. 4 illustrates the table with the calculated values of sensibility indicators in the learning process for our predictors' values introduced to network. The order of their being shown is not random, because they are sorted according to their importance for a chosen artificial neural network, from the least important to the most important.

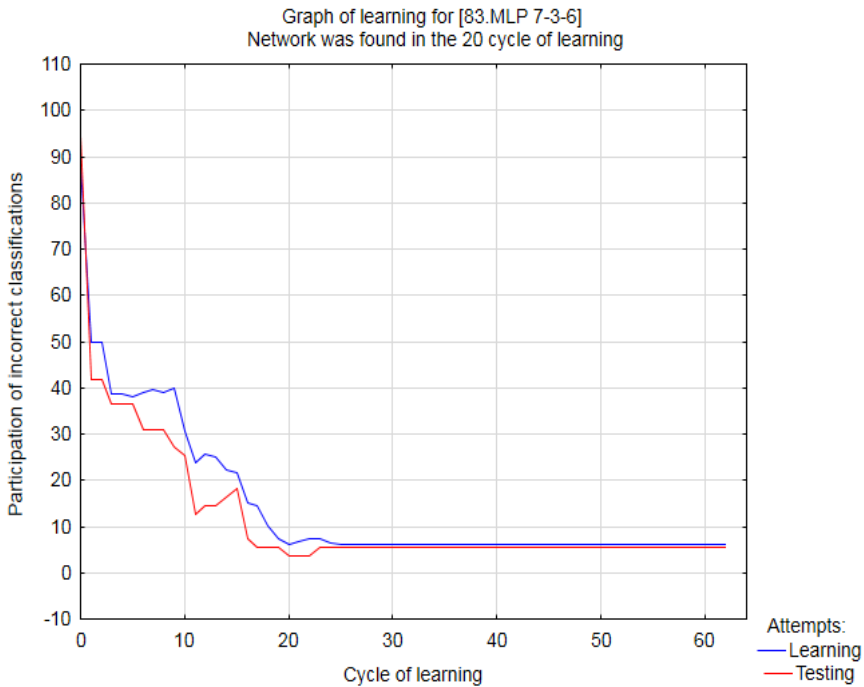


Fig. 3. Graph of learning for the chosen network for first tests of MG-25 fuses

Analysis of sensitivity (MG25 RB=1)							
Attempts: Learning							
Network	N	LC	NC	LE	LB	NB	LA
83.MLP 7-3-6	4,550680	4,230359	4,186000	2,759615	1,027970	1,026046	1,002150

Fig. 4. Table of sensitivity indicators for first tests of MG-25 fuses

For the neural network under consideration, a prediction was made of all previous post-diagnostic decisions, which were taken for a learning attempt. The fragment of prediction sheet for individual post-diagnostic decisions is displayed in fig. 5. This figure depicts a post-diagnostic decision B5 marked in red, which, according to the designed network, should be taken, but in reality, in test card, decision Z was taken. As seen above, some discrepancies are observed between the made predictions of the designed artificial neural network and decisions reached by persons evaluating test results.

Case name	Sheet of prediction for DEC (MG25 RB=1) Attempts: Learning			
	DEC Dependent variable	DEC - Exit 83. MLP 7-3-6	DEC - Validity 83. MLP 7-3-6	DEC - Levels of activation 83. MLP 7-3-6
154	PS	PS	Correct	0,998589
156	BP	BP	Correct	0,902365
157	B5	B5	Correct	0,861049
158	BP	BP	Correct	0,902365
159	Z	B5	Incorrect	0,861049
160	B5	B5	Correct	0,861049
161	B5	B5	Correct	0,861049
163	B5	B5	Correct	0,861049
166	B5	B5	Correct	0,861049
167	B3	B3	Correct	0,581243
168	B5	B5	Correct	0,861049
170	B5	B5	Correct	0,861049
171	BS	BS	Correct	0,841487
175	B5	B5	Correct	0,861049
176	B5	B5	Correct	0,861049
177	BP	BP	Correct	0,804910
178	B5	B5	Correct	0,861049
179	B5	B5	Correct	0,861049
180	B5	B5	Correct	0,861049
181	BS	BS	Correct	0,725681

Fig. 5. Fragment of prediction sheet of decision for first tests of MG-25 fuses

#### 4. Neural network for MG-37 fuses

In case of building the artificial neural network for first laboratory diagnostic tests of MG-37 fuses, the same assumptions were adopted as for MG-25 fuses, i.e. it was assumed that it will be a one-way MLP network. The database of test results was prepared according the same key as in the case of MG-25 fuses. Designing was started with the value of three neurons in the hidden layer and this number was increased as next networks were built. The use of the same four types of the activation function of the hidden layer and the activation function of output layer of softmax were also adopted. Moreover, 200 networks were also



built for every analysed activation function of the hidden layer and every number of the applied hidden neurons. As input signals, the same predictors were used as in the case of tests of MG-25 fuses. All predictors, together with LA variable, were statistically significant. Seven types of possible post-diagnostic decisions were adopted as output signals, which were determined in the research methodology.

As a result of the artificial neural networks for MG-37 fuses, which were designed and built according to the above mentioned assumptions, several hundred of networks with different values were obtained. The detailed comparative analysis of the designed neural networks enabled to select the MLP 8-3-7 network, Id network 166, the main parameters of which were shown in the summary in fig. 6.

Summary of active networks (MG37 RB=1)								
Id network	Name of network	Quality (learning)	Quality (testing)	Quality (validation)	Algorithm of learning	Error function	Activation (hidden)	Activation (exit)
166	MLP 8-3-7	88,68778	85,10638	82,97872	BFGS 61	Entropy	Tanh	Softmax

Fig. 6. Summary of the chosen network for first tests of MG-37 fuses

ID of weights	Weights of network (MG37 RB=1)	
	Connections 166.MLP 8-3-7	Values of weights 166.MLP 8-3-7
15	LD --> hidden neuron 2	45,380
16	LE --> hidden neuron 2	7,928
17	LA --> hidden neuron 3	0,008
18	LB --> hidden neuron 3	15,112
19	NB --> hidden neuron 3	15,099
20	N --> hidden neuron 3	-36,131
21	NC --> hidden neuron 3	43,615
22	LC --> hidden neuron 3	-6,139
23	LD --> hidden neuron 3	-4,152
24	LE --> hidden neuron 3	124,584
25	dislocation input --> hidden neuron 1	-2,362
26	dislocation input --> hidden neuron 2	18,529
27	dislocation input --> hidden neuron 3	-0,201
28	hidden neuron 1 --> DEC(B3)	-23,708
29	hidden neuron 2 --> DEC(B3)	0,233
30	hidden neuron 3 --> DEC(B3)	0,582
31	hidden neuron 1 --> DEC(B5)	-50,833
32	hidden neuron 2 --> DEC(B5)	7,172
33	hidden neuron 3 --> DEC(B5)	-41,841
34	hidden neuron 1 --> DEC(BP)	17,243
35	hidden neuron 2 --> DEC(BP)	22,836
36	hidden neuron 3 --> DEC(BP)	-60,037

Fig. 7. Fragment of weight values for first diagnostic tests of MG-37 fuses

We should take into account that the quality of the test for our neural network amounted to 85,11%, what is of course not as high result as in the case of MG-25 fuses, but it should be presumed that it is also good value of the quality of testing.

In the learning process, the neural network worked out a series of values of synaptic weights, which fragment of final quantities for our chosen neural network marked as 166.MLP 8-3-7 was presented in fig. 7.

Network	Analysis of sensitivity (MG37 RB=1) Attempts: Learning							
	NC	LE	N	LB	NB	LC	LD	LA
166.MLP 8-3-7	149,2172	101,7866	81,55153	45,35065	45,30984	12,64736	1,463286	1,008401

Fig. 8. Table of sensitivity indicators for first diagnostic tests of MG-37 fuses

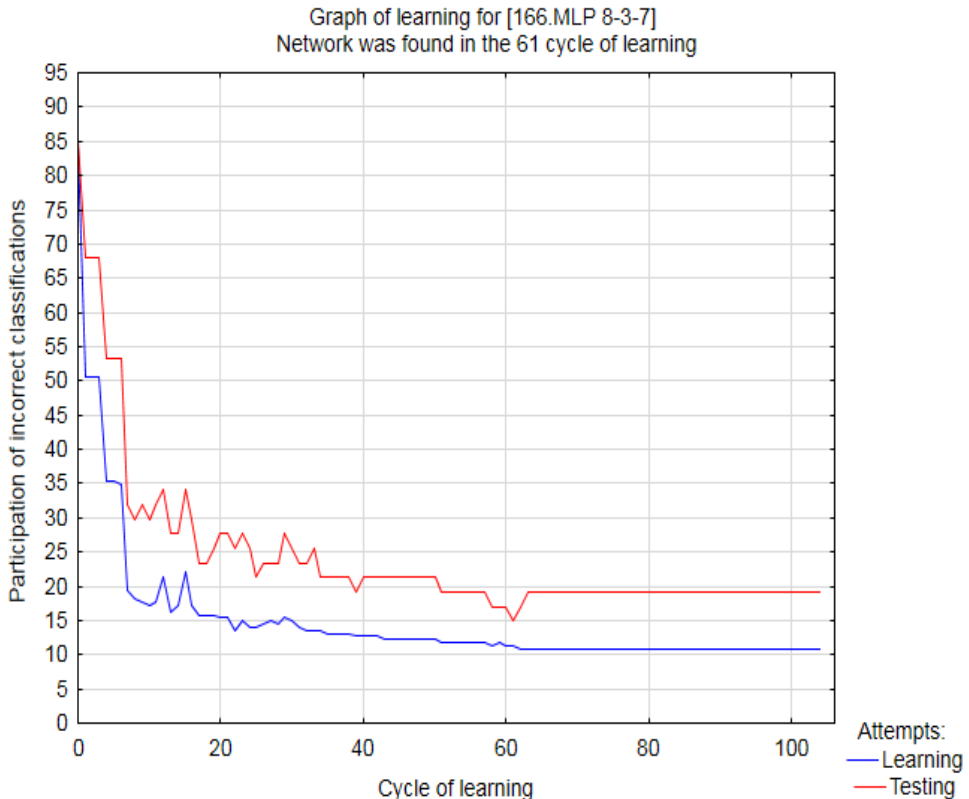


Fig. 9. Graph of learning for chosen network for first tests of MG-37 fuses

Figure 8 presents the calculated values of sensibility indicators in the learning process for the introduced predictors in the process of building the artificial neural network. Their

sequence indicates their importance for network. LA predictor is statistically the most significant.

The learning graph (figure 9), developed as a result of learning of neural network, shows that in 61 epoch, the network learnt to find the correct output signals, which means correct post-diagnostic decisions for tested MG-37 fuses for first laboratory diagnostic tests. As it can be observed, the process of finding the correct answers in this neural network lasted long enough.

The prediction was also made of all previously taken post-diagnostic decisions for a learning attempt. The fragment of sheet of these predictions is presented in figure 10. B5 decision marked in red is visible there. This decision, according to the built neural network, should be taken instead of PS decision taken by the person evaluating these test results. The divergence is relatively big, since B5 decision is a positive decision describing storage possibility for the following five years. However, PS decision orders the execution next of subsequent diagnostic tests according to the specific programme.

Case name	Sheet of prediction for DEC (MG37 RB=1) Attempts: Learning			
	DEC Dependent variable	DEC - Exit 166. MLP 8-3-7	DEC - Validity 166. MLP 8-3-7	DEC - Levels of activation 166. MLP 8-3-7
60	B5	B5	Correct	0,658292
61	B5	B5	Correct	0,769784
62	B5	B5	Correct	0,501420
63	B5	B5	Correct	0,819823
67	B5	B5	Correct	0,797790
68	B5	B5	Correct	0,588988
70	B5	B5	Correct	0,837425
71	B5	B5	Correct	0,837425
72	B5	B5	Correct	0,837425
73	B5	B5	Correct	0,837425
74	BP	BP	Correct	1,000000
75	PS	B5	Incorrect	0,837425
76	B5	B5	Correct	0,837425
77	B5	B5	Correct	0,837425
79	B5	B5	Correct	0,837425
80	B5	B5	Correct	0,837425
82	B5	B5	Correct	0,837425
83	B5	B5	Correct	0,837425
84	B5	B5	Correct	0,837425
85	B5	B5	Correct	0,837425

Fig. 10. Fragment of sheet prediction of decision for first tests of MG-37 fuses

## 5. Neural network for MG-57 fuses

By designing the artificial neural network for MG-57 fuses for first laboratory diagnostic tests, the same assumptions were adopted as in the case of the previous fuses. The database of test results was prepared according to the same requirements to create a homogeneous set of these test results. It was also assumed that the built network will be a one-way MLP network. At the beginning, three neurons were adopted in the hidden layer during simulation and this number was increased until 15 hidden neurons were achieved. Four types of activation function of hidden layer were applied i.e. a linear, logarithmic, exponential and tanh function. Softmax function was adopted as a function of output layer. Moreover, 200 different networks were also built for every analyzed activation function of the hidden layer. The same predictors' types were applied as in the case of MG-37 fuses. As output signals, six different possible post-diagnostic decisions were adopted, which were determined in the research methodology.

As a result of the designed and built artificial neural networks for MG-57 fuses, several hundred of networks with different parameter values were obtained. The detailed analysis of the designed neural networks enabled to choose a MLP 8-3-6 neural network, Id network 35, which main parameters were presented in the summary in fig. 11.

Summary of active networks (MG57 RB=1)								
Id network	Name of network	Quality (learning)	Quality (testing)	Quality (validation)	Algorithm of learning	Error function	Activation (hidden)	Activation (exit)
35	MLP 8-3-6	88,40336	87,40157	90,55118	BFGS 27	Entropia	Tanh	Softmax

**Fig. 11.** Summary of the chosen network for first tests of MG-57 fuses

The quality of testing was set at a level of 87,40% what is a good result for the built artificial neural network. The mutual entropy was adopted as the error function. The activation function for a chosen neural network is a tanh function; however, for the output layer- a softmax function.

The conducted learning process of network led to describe the individual synaptic weights, whose fragment of the final quantities for a chosen neural network marked as 35.MLP 8-3-6 was shown in fig. 12.

During learning process of network, the so-called graph of learning is created, which shows the number of epochs, after the passage of which, the built neural network begins to correctly find the output signals, which means in our case, to correctly determine the post-diagnostic decisions. In this case, the correct process began from 27 epoch. Graph of learning of this neural network was presented in fig. 13.

ID of weight	Weights of network (MG57 RB=1)	
	Connections 35.MLP 8-3-6	Values of weights 35.MLP 8-3-6
10	LB -> hidden neuron 2	-1,6536
11	NB -> hidden neuron 2	-1,4241
12	N -> hidden neuron 2	-2,2269
13	NC -> hidden neuron 2	-3,1330
14	LC -> hidden neuron 2	-3,1733
15	LD -> hidden neuron 2	0,2134
16	LE -> hidden neuron 2	5,6506
17	LA -> hidden neuron 3	-0,6988
18	LB -> hidden neuron 3	1,3643
19	NB -> hidden neuron 3	1,5043
20	N -> hidden neuron 3	0,8816
21	NC -> hidden neuron 3	-2,7077
22	LC -> hidden neuron 3	5,1320
23	LD -> hidden neuron 3	5,2209
24	LE -> hidden neuron 3	2,9499
25	dislocation input -> hidden neuron 1	-0,0295
26	dislocation input -> hidden neuron 2	1,2678
27	dislocation input -> hidden neuron 3	-0,9681
28	hidden neuron 1 -> DEC(B3)	4,3214
29	hidden neuron 2 -> DEC(B3)	2,9968
30	hidden neuron 3 -> DEC(B3)	-3,0783
31	hidden neuron 1 -> DEC(B5)	-11,0242

Fig. 12. Fragment values of weights for first diagnostic tests of MG-57 fuses

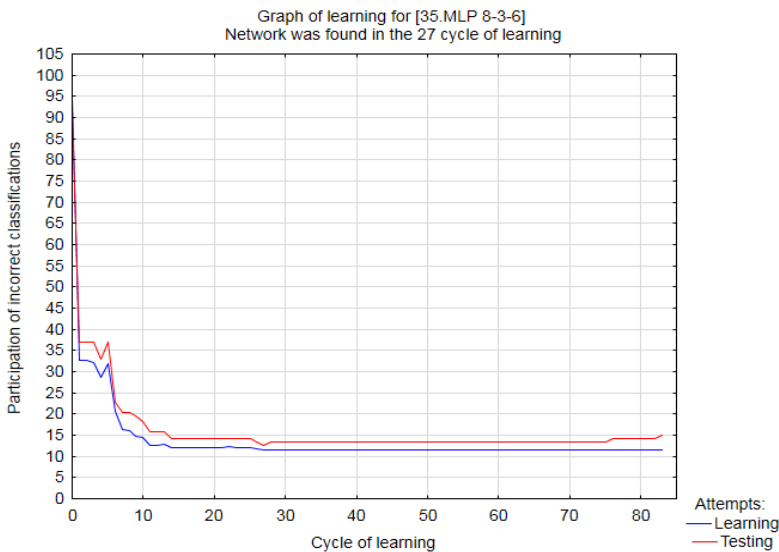


Fig. 13. Graph of learning for chosen network for first tests of MG-57 fuses

Analysis of sensitivity (MG57 RB=1) Attempts: Learning								
Network	LC	NC	N	LD	LE	NB	LB	LA
35.MLP 8-3-6	3,834546	2,018594	1,194772	1,084213	1,064117	1,054708	1,023436	0,998363

Fig. 14. Table of sensitivity indicators for first diagnostic tests of MG-57 fuses

Sheet of prediction for DEC (MG57 RB=1) Attempts: Learning					
Case name	DEC	DEC - Exit	DEC - Validity	DEC - Levels of activation	
	Dependent variable	35. MLP 8-3-6	35. MLP 8-3-6	35. MLP 8-3-6	
320	BP	BP	Correct	0,966131	
323	B5	B5	Correct	0,853005	
324	B5	B5	Correct	0,853005	
325	B5	B5	Correct	0,853005	
326	B5	B5	Correct	0,853005	
327	B5	B5	Correct	0,853005	
328	BS	BS	Correct	0,784566	
329	B3	B5	Incorrect	0,853005	
330	B5	B5	Correct	0,853005	
331	B5	B5	Correct	0,853005	
332	B5	B5	Correct	0,853005	
333	B5	B5	Correct	0,853005	
334	B5	B5	Correct	0,853005	
335	BP	BP	Correct	0,966131	
336	BP	BP	Correct	0,966131	
337	B5	B5	Correct	0,853005	
339	B5	B5	Correct	0,853005	
340	B5	B5	Correct	0,853005	
341	B5	B5	Correct	0,853005	
342	B5	B5	Correct	0,853005	
344	B5	B5	Correct	0,853005	
346	BS	BS	Correct	0,784566	
348	B5	B5	Correct	0,853005	
349	B5	B5	Correct	0,853005	
350	B5	B5	Correct	0,853005	

Fig. 15. Fragment of prediction sheet of decision for first tests of MG-57 fuses

Predictions of previously taken post-diagnostic decisions for all elements of the learning attempt were also made. The sheet fragment of these predictions is presented in figure 15, where B5 decision marked in red can be observed, which should be taken according to the built neural network, instead of B3 decision taken by a person evaluating test results. In this case, both B3 and B5 decisions are positive decisions. They only differ in the prediction period amounting to three or five years. Our artificial neural network proposes longer prediction of capability time of the tested technical object, which is MG-57 artillery fuse.

## **6. Conclusions**

The article described an attempt to design and build artificial neural network for three types of artillery MG fuses, which are applied in artillery cartridges. The purpose defined at the beginning of the article was fully accomplished. The parameters necessary to build correct structures of neural networks were determined, which in effect led to building neural networks with high values of quality indicators. Thanks to the modern, specialist computer software [4] simulation of the designed neural network was performed at different topologies of these networks and the best artificial neural network for every type of MG fuses was chosen among the received networks.

The built artificial neural network for first laboratory tests for MG-25 fuses of MLP 7-3-6 is distinguished by the best network parameters and its value of testing quality is at the very high level amounting to 96,36%. Similarly, MLP 8-3-7 neural network designed for first diagnostic tests for MG-37 fuses is also characterized by the best network parameters; however, in this case, testing quality of 85,11% was achieved. The last built network was the MLP 8-3-6 network for the first diagnostic tests for MG-57 fuses, which reached the level of testing quality of 87,40%. In all of the built models, high values of testing quality coefficients were obtained.

The built neural networks and their topology indicate that these networks do not require a high number of neurons in hidden neurons to function at the high- quality level. The article, due to volume restrictions, did not demonstrate other data, which unambiguously define and characterize the built neural networks for the analyzed MG fuses.

In conclusion, the evaluation process of the newly obtained test results of diagnostic laboratory tests for MG-25, MG-37 and MG-57 fuses can currently be made utilizing the artificial neural networks. The introduced new predictors' values for the built networks cause its rapid evaluation and automatically determine the prediction in the form of taking the appropriate post-diagnostic decision, obviously with the high probability level of making this decision. The replacement of the previous "manual" evaluation modules with the designed artificial neural networks for individual types of artillery fuses seems to be an indispensable necessity currently.

## **7. References**

1. Amunicja wojsk lądowych. Wydawnictwo Ministerstwa Obrony Narodowej, Szefostwo Służby Uzbrojenia i Elektroniki, 1985.
2. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Biocybernetyka i inżynieria biomedyczna. Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
3. Helt P., Parol M., Piotrowski P.: Metody sztucznej inteligencji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2012.
4. Statystyka 13.1 PL – Statsoft Polska 2016 r. – application software.

# **SIECI NEURONOWE DLA BADANYCH ZAPALNIKÓW ARTYLERYJSKICH TYPU MG**

## **1. Wprowadzenie**

Początek lat osiemdziesiątych ubiegłego wieku był to okres dynamicznego rozwoju nowej dziedziny nauki, jaką była teoria sztucznych sieci neuronowych. Sieci neuronowe mogą być zastosowane z dużym prawdopodobieństwem sukcesu wszędzie tam, gdzie pojawiają się problemy związane z tworzeniem modeli matematycznych pozwalających automatycznie odwzorować w komputerze różne złożone zależności pomiędzy pewnymi sygnałami wejściowymi a wyjściowymi. Dopasowanie sieci neuronowej do konkretnego problemu badawczego odbywa się poprzez dobór zmiennych parametrów sieci tak, aby zachowanie modelu zgadzało się (w określonym sensie) z działaniem rzeczywistego systemu.

Sieci neuronowe według [2] powodują w pewnym sensie automatyzację procesów ocenowych analizowanych wyników badań, w przypadku kiedy proces podejmowania decyzji jest oparty na danych ilościowych, przy minimalnym tylko udziale danych opisowych i symptomów wyrażanych w kategoriach wyłącznie jakościowych. Jednak byłoby błędem przypuszczenie, że liczbowa (numeryczna) postać symptomów i innych wejściowych cech stanowi warunek zastosowania sieci neuronowych w diagnostyce. Przeciwnie, są dowody, że w odróżnieniu od innych metod komputerowych (na przykład w odróżnieniu od analizy dyskryminacyjnej) przy korzystaniu z sieci neuronowych bardzo dobre wyniki uzyskano także w zastosowaniach tej techniki do diagnozowania problemów niedających się sformalizować w przestrzeni liczbowej.

Ponadto zgodnie z [3], sztuczne sieci neuronowe mają także zastosowanie w predykcji określonych zjawisk i zdarzeń, czyli mają zdolność do prognozowania danych wyjściowych (przyszłych zdarzeń) na podstawie nauczonych danych wejściowych, oczywiście skorelowanych z odpowiadającymi im danymi wyjściowymi. Jest to cecha, którą można z powodzeniem wykorzystać w badaniach diagnostycznych elementów środków bojowych, dlatego też podjęto próbę opracowania takiego modelu ocenowego w oparciu o uzyskiwane empiryczne wyniki sprawdzeń badanych zapalników.

Celem pracy było zaprojektowanie oraz zbudowanie sztucznych sieci neuronowych dla każdego rodzaju zapalnika artyleryjskiego typu MG rozpatrywanego w tym artykule. Do realizacji tak postawionego celu wybrano zapalniki typu MG-25, MG-37 oraz MG-57. Bazy wyników badań tych zapalników są dość liczne, co daje duże prawdopodobieństwo opracowania sztucznych sieci neuronowych o wysokim poziomie jakościowym ich pracy. Artykuł prezentuje możliwość zastosowania sztucznych sieci neuronowych do wspomagania



nia podejmowania decyzji podiagnostycznych dla badanych zapalników artyleryjskich. Projektowane sieci neuronowe dotyczyły tylko modułów ocenowych badanych zapalników w zakresie pierwszych laboratoryjnych badań diagnostycznych.

## **2. Budowa sieci neuronowych dla zapalników artyleryjskich**

Do projektowanych sztucznych sieci neuronowych przygotowano znaczną liczbę wyników pierwszych laboratoryjnych badań diagnostycznych zapalników artyleryjskich typu MG-25, MG-37 oraz MG-57.

Zapalniki typu MG-25 stosowane są w 23 mm nabojach z pociskiem odłamkowo-burząco-zapalająco-smugowym do armaty przeciwlotniczej oraz w 25 mm nabojach z pociskiem odłamkowo-burząco-zapalająco-smugowym, zapalniki typu MG-37 stosowane są w 37 mm nabojach z pociskiem odłamkowo-smugowym do armaty wzór 39, natomiast zapalniki typu MG-57 stosowane są w 57 mm nabojach z pociskiem odłamkowo-smugowym do armaty wzór S-60 i S-68.

Wszystkie trzy rodzaje analizowanych zapalników są zapalnikami głowicowymi [1], mechanicznymi o działaniu z krótką zwłoką z samolikwidatorem bez zabezpieczenia. Główne elementy tych zapalników to: spłonka zapalająca, sprężyna, spłonka pobudzająca, ładunek pobudzający, iglica i masa pirotechniczna. Oprócz tych elementów każdy z nich posiada jeszcze kilka innych, które także podlegają obowiązkowym sprawdzeniom podczas laboratoryjnych pierwszych badań diagnostycznych.

W zakres badań i prób laboratoryjnych zapalników artyleryjskich wchodzi m.in.: sprawdzenie hermetyczności zapalników, sprawdzenie wyglądu zewnętrznego oraz stanu powierzchni, sprawdzenie prawidłowości montażu oraz stanu powierzchni zespołów i części, badania prawidłowości działania spłonek zapalających i pobudzających, sprawdzenie niezawodności działania łańcucha ogniowego zapalników, badania fizykochemiczne materiałów wybuchowych znajdujących się w zespołach zapalników. Badania laboratoryjne zapalników są dwustopniowe. W pierwszym badaniu kontroluje się poszczególne zespoły i części oraz sprawdza się główne parametry danego typu zapalnika. Zakres drugiego badania ustalany jest w zależności od liczby i kwalifikacji niezgodności, które wystąpiły w pierwszym badaniu. Z tego też względu, zaprojektowanie sztucznych sieci neuronowych dla drugich laboratoryjnych badań diagnostycznych będzie nieco większym problemem z uwagi na brak jednolitych kryteriów. Autor przewiduje taką możliwość, jednakże będzie to przedmiotem oddzielnego artykułu.

Z posiadanych baz danych rozpatrywanych w artykule typów zapalników wyeliminowano wyniki tzw. dociekań naukowo-badawczych, których zakres odbiega od pozostałych standardowych badań diagnostycznych. Nie analizowano również wyników badań diagnostycznych przeprowadzonych dla innych resortów niż resort obrony narodowej, czyli zgodnie z metodyką badawczą analizowano wyniki badań, dla których rodzaj badania wynosił wartość jeden ( $RB = 1$ ), co oznacza składowanie tych próbek badawczych zapalników w podzbiórze przechowywania określonym w metodycie

badawczej<sup>1</sup> jako „K”. Te wszystkie ograniczenia przygotowanych zbiorów wyników danych miały na celu stworzenie jednorodnych zbiorów wyników badań, które będą mogły być analizowane podczas budowy sztucznych sieci neuronowych dla zapalników artyleryjskich typu MG.

Laboratoryjne badania diagnostyczne każdego z tych trzech rodzajów zapalników artyleryjskich polegają więc na badaniu ich właściwości (cech), które według metodyki badawczej zostały podzielone na pięć klas ważności (niezgodności): A, B, C, D i E. W zależności od liczby wykrytych niezgodności w poszczególnych klasach ważności podczas badań laboratoryjnych, otrzymuje się określoną zgodnie z danym modulem ocenowym decyzję podiagnostyczną dla konkretnego zapalnika.

W budowanych modelach sztucznych sieci neuronowych analizowano tylko moduły ocenowe oraz przyjęto, że wszystkie badane cechy danego zapalnika typu MG oraz informacje o liczbie zapalników niezgodnych w poszczególnych klasach ważności stanowiły w naszych przypadkach sygnały wejściowe (predyktory) projektowanych sieci neuronowych. Predyktory te były dostarczane do budowanych sieci w postaci zapisu jako oznaczenie liczbowe, tzn. jeżeli podczas badania diagnostycznego nie stwierdzono żadnych niezgodności danej klasy ważności, wówczas dostarczana była wartość zero. Natomiast, w przypadku kiedy podczas badań wykryto niezgodności, podawana była konkretna liczba tych niezgodności w danej klasie ważności. Budowane sieci neuronowe dla wszystkich typów zapalników artyleryjskich składały się tylko z jednej warstwy ukrytej. Parametrami wyjściowymi dla projektowanych sieci neuronowych były określone w metodyce badawczej decyzje podiagnostyczne. Liczba tych parametrów uzależniona jest od liczby możliwych do podjęcia decyzji podiagnostycznych, które zostały określone w module ocenowym dla konkretnego typu zapalnika.

Dostarczone wartości predyktorów będą więc pobudzeniem neuronów znajdujących się w warstwach ukrytych, gdzie przekształcane będą przez określone funkcje aktywacji neuronów. Wartości obliczone przez te funkcje będą ostatecznie wartościami wyjściowymi, czyli parametrami wyjściowymi tych warstw neuronowych. Zachowanie wszystkich neuronów ukrytych było więc bardzo silnie uzależnione od rodzaju używanej funkcji aktywacji. We wszystkich budowanych sztucznych sieciach neuronowych przyjęto cztery rodzaje funkcji aktywacji warstw ukrytych: funkcję logistyczną, wykładniczą, tangensa hiperbolicznego oraz liniową.

Ważnym elementem w projektowaniu sieci neuronowych jest również przyjęcie funkcji aktywacji dla warstwy wyjściowej. W tym przypadku dla wszystkich budowanych sztucznych sieci neuronowych została przyjęta funkcja typu softmax, jako najbardziej odpowiednia dla analizowanego problemu badawczego.

Kolejną kwestią, którą należało określić, był sposób łączenia się ze sobą neuronów. Po przeprowadzonej analizie zapalników zaproponowano jednokierunkowe sieci neuronowe typu *feedforward*, ponieważ stwierdzono, że ten typ sieci najbardziej pasuje do rozpatrywanego problemu badawczego.

---

<sup>1</sup> Metodyka badań diagnostycznych amunicji. Indeks N-5001b, 1985. Archiwum WITU.

Zastosowano połączenia neuronów typu każdy z każdym pomiędzy poszczególnymi warstwami budowanych modeli sieci neuronowych, co pozwoliło na stworzenie sieci o nazwie perceptron wielowarstwowy (MLP).

Następnym problemem podczas projektowania sieci było określenie liczby neuronów w warstwach ukrytych. Określanie tych wielkości metodą prób i błędów może trwać miesiącami, ale dzięki nowoczesnemu oprogramowaniu komputerowemu [4] można przeprowadzić symulacje i określić je znacznie szybciej. Jednakże i tą metodą szukanie najbardziej odpowiedniej sieci neuronowej może trwać tygodniami, ponieważ powinno się rozpatrzyć różne wielkości neuronów ukrytych i tym samym powinno się zbudować kilkaset sztucznych sieci neuronowych.

Kolejnym krokiem było określenie wartości współczynników wagowych (wag synaptycznych) dla poszczególnych predyktorów. Wartości te były losowo ustalane przez oprogramowanie, które w miarę kolejnych obliczeń i analiz samo wprowadzało konkretną wartość wagi i korygowało ją, aby uzyskać najwyższe prawdopodobieństwa obliczanych wartości wskaźników jakości.

Każda budowana sieć musiała przejść żmudną drogę procesu uczenia się sieci, który jest jak wiadomo procesem interdeterministycznym. Jest wiele metod uczenia, ale w naszym przypadku przyjęto najczęściej stosowaną metodę wstecznej propagacji błędów (*backpropagation*).

Na początku przygotowano dwa ciągi danych: ciąg uczący i ciąg testujący. Do symulacji projektowanych sieci neuronowych wygenerowano do ciągu uczącego 70% posiadanych wyników badań. Po przetworzeniu całego ciągu uczącego (zwanego epoką) obliczono błąd epoki i cały cykl budowy danej sieci powtarzany był do momentu, aż błąd ten spadł poniżej przyjętego przez twórcę sieci określonego dopuszczalnego poziomu.

Nauczone sieci były sprawdzane za pomocą ciągu testującego, do którego wytypowano 15% posiadanych wyników badań, przy czym dane te nie były wcześniej używane. Ciąg ten służył do przeprowadzenia niezależnej kontroli postępów przyjętego algorytmu uczenia.

Ostatnim etapem była walidacja zbudowanych sieci neuronowych, czyli badanie sieci na zdolność do generalizacji na określonym zbiorze walidacyjnym. Do ciągów walidacyjnych wygenerowano również 15% posiadanych wyników badań, które nie były wcześniej wprowadzone ani do ciągów uczących ani do ciągów testujących. Walidacja zaprojektowanych sieci neuronowych była kolejnym sprawdzeniem poprawności funkcjonowania zbudowanych sztucznych sieci neuronowych.

### **3. Sieć neuronowa zapalników typu MG-25**

Projektowanie sztucznej sieci neuronowej dla zapalników typu MG-25 dla pierwszych badań diagnostycznych rozpoczęto od założenia, że sieć ta będzie siecią jednokierunkową typu MLP. Wszystkie neurony w sieci będą połączone ze sobą na zasadzie każdy z każdym.

Początkowo przyjęto funkcję sigmoidalną jako funkcję aktywacji warstwy ukrytej oraz założono trzy neurony ukryte w tej warstwie. W celu znalezienia najlepszej sieci

neuronowej, wprowadzano następne neurony do warstwy ukrytej, kończąc na wartości 15 neuronów ukrytych. Wyznaczono zbiory: uczący, testujący i walidacyjny w proporcjach określonych wyżej. Zbudowano po 200 sieci dla każdej analizowanej funkcji aktywacji warstwy ukrytej oraz dla każdej liczby użytych neuronów ukrytych w budowanych sieciach neuronowych. Jako sygnały wyjściowe przyjęto sześć rodzajów możliwych do przyjęcia decyzji podiagnostycznych zgodnie z metodyką. Nie uwzględniono jako predyktora wartości niezgodności klasy A – predyktor LA, bo zmienna ta nie była istotna statystycznie.

Podsumowanie aktywnych sieci (MG25 RB=1)								
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
83	MLP 7-3-6	93,89313	96,36364	94,54545	BFGS 20	Entropia	Tanh	Softmax

Rys. 1. Podsumowanie wybranej sieci dla pierwszych badań zapalników MG-25

W efekcie otrzymano różne parametry zaprojektowanych sieci neuronowych. Po dokładnej analizie tych parametrów wybrano jedną najlepszą sieć neuronową dla pierwszych badań diagnostycznych postaci MLP 7-3-6, Id sieci 83, której główne parametry zostały przedstawione na rys. 1.

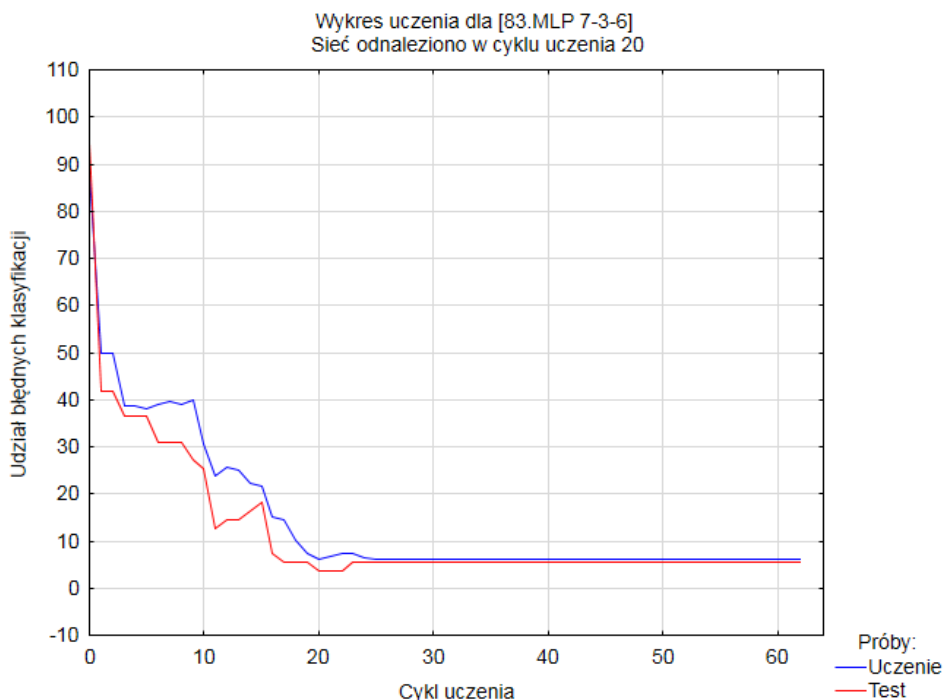
ID wagi	Wagi sieci (MG25 RB=1)	
	Połączenia 83.MLP 7-3-6	Wartości wag 83.MLP 7-3-6
10	NB --> ukryty neuron 2	-2,6933
11	N --> ukryty neuron 2	-7,0008
12	NC --> ukryty neuron 2	-7,7620
13	LC --> ukryty neuron 2	-7,8803
14	LE --> ukryty neuron 2	-3,4348
15	LA --> ukryty neuron 3	0,1065
16	LB --> ukryty neuron 3	-0,0770
17	NB --> ukryty neuron 3	-0,0172
18	N --> ukryty neuron 3	-0,2287
19	NC --> ukryty neuron 3	-0,5834
20	LC --> ukryty neuron 3	-0,2091
21	LE --> ukryty neuron 3	-11,1534
22	przesunięcie wejściowych --> ukryty neuron 1	-0,3771
23	przesunięcie wejściowych --> ukryty neuron 2	3,9544
24	przesunięcie wejściowych --> ukryty neuron 3	-0,0065
25	ukryty neuron 1 --> DEC(B3)	-1,0940
26	ukryty neuron 2 --> DEC(B3)	-2,6204
27	ukryty neuron 3 --> DEC(B3)	4,1884
28	ukryty neuron 1 --> DEC(B5)	-8,4479
29	ukryty neuron 2 --> DEC(B5)	1,6489
30	ukryty neuron 3 --> DEC(B5)	3,9224

Rys. 2. Fragment wartości wag dla pierwszych badań zapalników MG-25

Podstawowym parametrem, który został uwzględniony podczas wyboru najlepszej sieci neuronowej, była uzyskana wartość jakości testowania dla danej sieci. Parametr ten określa dokładność zbudowanej sieci. W tym przypadku osiągnięto wartość wynoszącą 96,36, co jest bardzo dobrym wynikiem podczas budowania sieci neuronowych. Kolejnym bardzo ważnym czynnikiem wyboru zbudowanej sieci była jej topologia. Oczywiście wzięto pod uwagę kolejne parametry, które ewidentnie wskazały na wyższość wybranej sieci w porównaniu do innych, które miały nieco gorsze wskaźniki.

Podczas budowy tej sieci stosowany był algorytm uczenia typu BFGS. Otrzymano wartość 20 epoki, przy której zostały osiągnięte przedstawione w podsumowaniu wartości jakości. Projektując sieć, użyto funkcji błędu postaci entropii wzajemnej oraz funkcji tangensa hiperbolicznego aktywacji warstwy ukrytej. Jako funkcję aktywacji warstwy wyjściowej użyto, jak już wspomniano wcześniej, funkcji typu softmax.

W procesie uczenia w kolejnych krokach iteracyjnych projektowana sieć wypracowywała losowo szereg wartości wag synaptycznych, które były zmieniane w procesie budowy połączeń w kolejnych nowych sieciach neuronowych, w związku z występowaniem tzw. błędów uczenia. Fragment ostatecznych wielkości tych współczynników wagowych dla naszej sieci neuronowej postaci 83.MLP 7-3-6 zostały przedstawione na rys. 2.



**Rys. 3.** Wykres uczenia dla wybranej sieci dla pierwszych badań zapalników MG-25

Na rys. 3 pokazany został wykres uczenia się sieci dla wybranej sztucznej sieci neuronowej. Na wykresie można zauważyć 20 epokę, przy której sieć finalnie nauczyła się prawidłowo odnajdywać wartości sygnałów wyjściowych.

Rys. 4 przedstawia tabelę z obliczonymi wartościami wskaźników wrażliwości w procesie uczenia dla wprowadzonych do sieci naszych wartości predyktorów. Kolejność ich pokazania nie jest przypadkowa, są posortowane według ich ważności dla wybranej sztucznej sieci neuronowej, od najmniej ważnych po najważniejsze.

		Analiza wrażliwości (MG25 RB=1)						
		Próby: Uczenie						
Sieć		N	LC	NC	LE	LB	NB	LA
83.MLP 7-3-6		4,550680	4,230359	4,186000	2,759615	1,027970	1,026046	1,002150

Rys. 4. Tabela wskaźników wrażliwości dla pierwszych badań zapalników MG-25

		Arkusz predykcji dla DEC (MG25 RB=1)			
		Próby: Uczenie			
Przypadek nazwa	DEC Zm.zal	DEC - Wyjście 83. MLP 7-3-6	DEC - Trafność 83. MLP 7-3-6	DEC - Poziomy aktywacji 83. MLP 7-3-6	
154	PS	PS	Poprawne	0,998589	
156	BP	BP	Poprawne	0,902365	
157	B5	B5	Poprawne	0,861049	
158	BP	BP	Poprawne	0,902365	
159	Z	B5	Niepoprawne	0,861049	
160	B5	B5	Poprawne	0,861049	
161	B5	B5	Poprawne	0,861049	
163	B5	B5	Poprawne	0,861049	
166	B5	B5	Poprawne	0,861049	
167	B3	B3	Poprawne	0,581243	
168	B5	B5	Poprawne	0,861049	
170	B5	B5	Poprawne	0,861049	
171	BS	BS	Poprawne	0,841487	
175	B5	B5	Poprawne	0,861049	
176	B5	B5	Poprawne	0,861049	
177	BP	BP	Poprawne	0,804910	
178	B5	B5	Poprawne	0,861049	
179	B5	B5	Poprawne	0,861049	
180	B5	B5	Poprawne	0,861049	
181	BS	BS	Poprawne	0,725681	

Rys. 5. Fragment arkusza predykcji decyzji dla pierwszych badań zapalników MG-25

Dla omawianej sieci neuronowej dokonano również predykcji wszystkich dotychczasowych podjętych dla próby uczącej decyzji podiagnostycznych. Fragment

arkusza predykcji dla poszczególnych decyzji podiagnostycznych przedstawia rys. 5. Na rysunku zaznaczono na czerwono decyzję podiagnostyczną B5, która według zaprojektowanej sieci powinna być podjęta, a w rzeczywistości w karcie badań podjęto decyzję Z. Jak widać powstają więc pewne rozbieżności pomiędzy dokonanymi predykcjami zbudowanej sztucznej sieci neuronowej a decyzjami podjętymi przez osoby oceniające wyniki badań.

## 4. Sieć neuronowa zapalników typu MG-37

W przypadku budowy sztucznej sieci neuronowej dla pierwszych laboratoryjnych badań diagnostycznych zapalników typu MG-37, przyjęto takie same założenia jak dla zapalników MG-25, tzn. założono m.in., że będzie to sieć jednokierunkowa typu MLP. Baza wyników badań była przygotowana według tego samego klucza co w przypadku zapalników MG-25. Projektowanie rozpoczęto również od wartości trzech neuronów w warstwie ukrytej i zwiększano tę liczbę w miarę budowy następnych sieci. Założono także zastosowanie tych samych czterech rodzajów funkcji aktywacji warstwy ukrytej oraz funkcję aktywacji warstwy wyjściowej typu softmax. Zbudowano również po 200 sieci dla każdej analizowanej funkcji aktywacji warstwy ukrytej oraz każdej liczby zastosowanych neuronów ukrytych. Jako sygnałów wejściowych użyto tych samych predyktorów jak w przypadku badań zapalników MG-25. Wszystkie predyktory łącznie ze zmienną LA były istotne statystycznie. Jako sygnały wyjściowe zostało przyjętych siedem rodzajów możliwych do podjęcia decyzji podiagnostycznych, które zostały określone w metodyce badawczej.

Podsumowanie aktywnych sieci (MG37 RB=1)								
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
166	MLP 8-3-7	88,68778	85,10638	82,97872	BFGS 61	Entropia	Tanh	Softmax

**Rys. 6.** Podsumowanie wybranej sieci dla pierwszych badań zapalników MG-37

W wyniku zaprojektowanych i zbudowanych według ww. założeń sztucznych sieci neuronowych dla zapalników typu MG-37 otrzymano kilkaset sieci o różnych wartościach parametrów charakteryzujących te sieci. Po dokładnej analizie porównawczej zaprojektowanych sieci neuronowych wybrano sieć neuronową postaci MLP 8-3-7, Id sieci 166, której główne parametry zostały pokazane w podsumowaniu na rys. 6.

Należy zwrócić uwagę na fakt, że jakość testowa dla naszej sieci neuronowej wyniosła 85,11%, co nie jest oczywiście tak wysokim wynikiem jak w przypadku zapalników MG-25, ale należy przyjąć, że ta wartość jest również dobrą wartością jakości testowania.

W zaprojektowanej sieci neuronowej, jako funkcję błędu przyjęto również entropię wzajemną, funkcją aktywacji dla warstwy ukrytej jest również funkcja tangensa hiperbolicznego, natomiast dla warstwy wyjściowej funkcja softmax.

W procesie uczenia sieć neuronowa wypracowała szereg wartości wag synaptycznych, których fragment ostatecznych wielkości dla naszej wybranej sieci neuronowej oznaczonej jako 166.MLP 8-3-7 został przedstawiony na rys. 7.

ID wagi	Wagi sieci (MG37 RB=1)	
	Połączenia 166.MLP 8-3-7	Wartości wag 166.MLP 8-3-7
15	LD --> ukryty neuron 2	45,380
16	LE --> ukryty neuron 2	7,928
17	LA --> ukryty neuron 3	0,008
18	LB --> ukryty neuron 3	15,112
19	NB --> ukryty neuron 3	15,099
20	N --> ukryty neuron 3	-36,131
21	NC --> ukryty neuron 3	43,615
22	LC --> ukryty neuron 3	-6,139
23	LD --> ukryty neuron 3	-4,152
24	LE --> ukryty neuron 3	124,584
25	przesunięcie wejściowych --> ukryty neuron 1	-2,362
26	przesunięcie wejściowych --> ukryty neuron 2	18,529
27	przesunięcie wejściowych --> ukryty neuron 3	-0,201
28	ukryty neuron 1 --> DEC(B3)	-23,708
29	ukryty neuron 2 --> DEC(B3)	0,233
30	ukryty neuron 3 --> DEC(B3)	0,582
31	ukryty neuron 1 --> DEC(B5)	-50,833
32	ukryty neuron 2 --> DEC(B5)	7,172
33	ukryty neuron 3 --> DEC(B5)	-41,841
34	ukryty neuron 1 --> DEC(BP)	17,243
35	ukryty neuron 2 --> DEC(BP)	22,836
36	ukryty neuron 3 --> DEC(BP)	-60,037

Rys. 7. Fragment wartości wag dla pierwszych badań zapalników MG-37

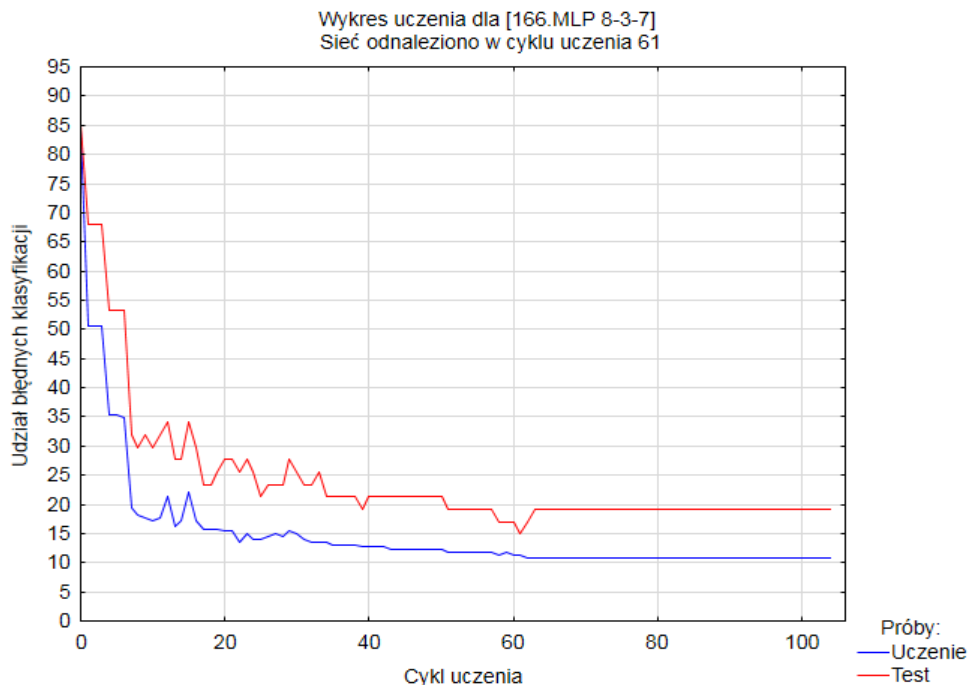
Sieć	Analiza wrażliwości (MG37 RB=1)							
	Próby: Uczenie							
	NC	LE	N	LB	NB	LC	LD	LA
166.MLP 8-3-7	149,2172	101,7866	81,55153	45,35065	45,30984	12,64736	1,463286	1,008401

Rys. 8. Tabela wskaźników wrażliwości dla pierwszych badań zapalników MG-37

Rys. 8 przedstawia obliczone wartości wskaźników wrażliwości w procesie uczenia dla wprowadzonych predyktorów podczas budowy sztucznej sieci neuronowej. Ich



kolejność wskazuje na ważność dla sieci – największe znaczenie statystyczne ma predyktor LA.



**Rys. 9.** Wykres uczenia dla wybranej sieci dla pierwszych badań zapalników MG-37

Powstały w wyniku uczenia się sieci neuronowej wykres uczenia (rys. 9) pokazuje, że w 61 epoce sieć nauczyła się odnajdywać prawidłowe sygnały wyjściowe, czyli poprawne decyzje podiagnostyczne dla badanych zapalników typu MG-37 dla pierwszych laboratoryjnych badań diagnostycznych. Jak widać, proces szukania poprawnych odpowiedzi w tej sieci neuronowej trwał dosyć długo.

Wykonano również predykcję wszystkich dotychczas podjętych dla próby uczącej decyzji podiagnostycznych. Fragment arkusza tych predykcji przedstawia rys. 10. Widać na nim zaznaczoną na czerwono decyzję B5, która według zbudowanej sieci neuronowej powinna być podjęta, zamiast decyzji PS podjętej przez osobę oceniającą te wyniki badań. Rozbieżność jest dość duża, ponieważ decyzja B5 jest decyzją pozytywną mówiącą o możliwości składowania przez kolejnych pięć lat, natomiast decyzja PS nakazuje przeprowadzenie kolejnych badań diagnostycznych według programu specjalnego.

Przypadek nazwa	Arkusz predykcji dla DEC (MG37 RB=1) Próby: Uczenie			
	DEC Zm.zal	DEC - Wyjście 166. MLP 8-3-7	DEC - Trafność 166. MLP 8-3-7	DEC - Poziomy aktywacji 166. MLP 8-3-7
60	B5	B5	Poprawne	0,658292
61	B5	B5	Poprawne	0,769784
62	B5	B5	Poprawne	0,501420
63	B5	B5	Poprawne	0,819823
67	B5	B5	Poprawne	0,797790
68	B5	B5	Poprawne	0,588988
70	B5	B5	Poprawne	0,837425
71	B5	B5	Poprawne	0,837425
72	B5	B5	Poprawne	0,837425
73	B5	B5	Poprawne	0,837425
74	BP	BP	Poprawne	1,000000
75	PS	B5	Niepoprawne	0,837425
76	B5	B5	Poprawne	0,837425
77	B5	B5	Poprawne	0,837425
79	B5	B5	Poprawne	0,837425
80	B5	B5	Poprawne	0,837425
82	B5	B5	Poprawne	0,837425
83	B5	B5	Poprawne	0,837425
84	B5	B5	Poprawne	0,837425
85	B5	B5	Poprawne	0,837425

Rys. 10. Fragment arkusza predykcji decyzji dla pierwszych badań zapalników MG-37

## 5. Sieć neuronowa zapalników typu MG-57

Podczas projektowania sztucznej sieci neuronowej dla zapalników typu MG-57 dla pierwszych laboratoryjnych badań diagnostycznych przyjęto te same założenia jak w przypadku poprzednich zapalników. Baza wyników badań była przygotowana według tych samych wymagań, aby stworzyć jednorodny zbiór tych wyników danych. Założono też, że budowana sieć będzie siecią jednokierunkową typu MLP. Na początku przyjęto trzy neurony w warstwie ukrytej podczas symulacji i zwiększano tę liczbę, kończąc na 15 neuronach ukrytych. Zastosowano cztery rodzaje funkcji aktywacji warstwy ukrytej, tzn. funkcję liniową, logarymiczną, wykładniczą oraz tangensa hiperbolicznego. Jako funkcję warstwy wyjściowej przyjęto funkcję typu softmax. Zbudowano również po 200 różnych sieci dla każdej analizowanej funkcji aktywacji warstwy ukrytej. Użyto tych samych rodzajów predyktorów co w przypadku zapalników typu MG-37. Jako sygnały wyjściowe zostało przyjętych sześć różnych możliwych do podjęcia decyzji podiagnostycznych, które zostały określone w metodyce badawczej.

Podsumowanie aktywnych sieci (MG57 RB=1)								
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
35	MLP 8-3-6	88,40336	87,40157	90,55118	BFGS 27	Entropia	Tanh	Softmax

**Rys. 11.** Podsumowanie wybranej sieci dla pierwszych badań zapalników MG-57

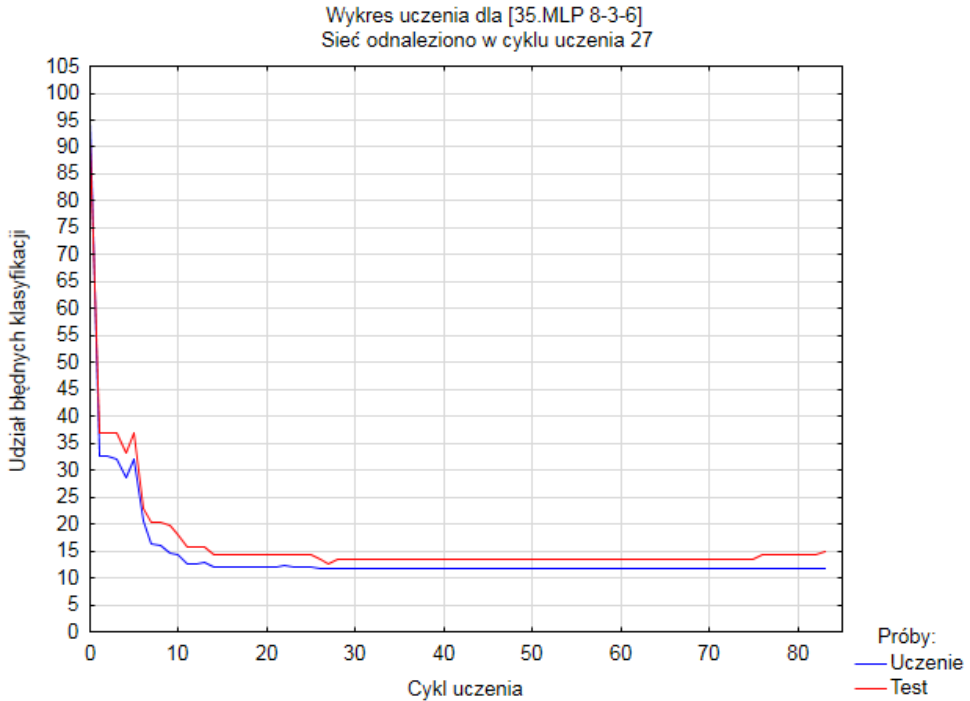
ID wagi	Wagi sieci (MG57 RB=1)	
	Połączenia 35.MLP 8-3-6	Wartości wag 35.MLP 8-3-6
10	LB -> ukryty neuron 2	-1,6536
11	NB -> ukryty neuron 2	-1,4241
12	N -> ukryty neuron 2	-2,2269
13	NC -> ukryty neuron 2	-3,1330
14	LC -> ukryty neuron 2	-3,1733
15	LD -> ukryty neuron 2	0,2134
16	LE -> ukryty neuron 2	5,6506
17	LA -> ukryty neuron 3	-0,6988
18	LB -> ukryty neuron 3	1,3643
19	NB -> ukryty neuron 3	1,5043
20	N -> ukryty neuron 3	0,8816
21	NC -> ukryty neuron 3	-2,7077
22	LC -> ukryty neuron 3	5,1320
23	LD -> ukryty neuron 3	5,2209
24	LE -> ukryty neuron 3	2,9499
25	przesunięcie wejściowych -> ukryty neuron 1	-0,0295
26	przesunięcie wejściowych -> ukryty neuron 2	1,2678
27	przesunięcie wejściowych -> ukryty neuron 3	-0,9681
28	ukryty neuron 1 -> DEC(B3)	4,3214
29	ukryty neuron 2 -> DEC(B3)	2,9968
30	ukryty neuron 3 -> DEC(B3)	-3,0783
31	ukryty neuron 1 -> DEC(B5)	-11,0242

**Rys. 12.** Fragment wartości wag dla pierwszych badań zapalników MG-57

W wyniku zaprojektowanych i zbudowanych sztucznych sieci neuronowych dla zapalników typu MG-57 otrzymano kilkaset sieci o różnych wartościach parametrów charakteryzujących te sieci neuronowe. Dokładna analiza zaprojektowanych sieci neuronowych doprowadziła do wyboru sieci neuronowej postaci: MLP 8-3-6, Id sieci 35, której główne parametry zostały przedstawione w podsumowaniu na rys. 11.

Jakość testowania została określona na poziomie 87,40%, co jest dobrym wynikiem dla zbudowanej sztucznej sieci neuronowej. Jako funkcję błędu przyjęto entropię wzajemną, funkcją aktywacji dla wybranej sieci neuronowej jest także funkcja tangensa hiperbolicznego, natomiast dla warstwy wyjściowej funkcja typu softmax.

Przeprowadzony proces uczenia się sieci doprowadził do określenia poszczególnych wag synaptycznych, których fragment ostatecznych wielkości dla wybranej sieci neuronowej oznaczonej jako 35.MLP 8-3-6 został pokazany na rys. 12.



Rys. 13. Wykres uczenia dla wybranej sieci dla pierwszych badań zapalników MG-57

Podczas procesu uczenia się sieci powstaje tzw. wykres uczenia pokazujący liczbę epok, po przejściu których budowana sieć neuronowa zaczyna prawidłowo odnajdywać sygnały wyjściowe, czyli w naszym przypadku zaczyna określać poprawne decyzje podiagnostyczne. W tym przypadku prawidłowy proces rozpoczął się od 27 epoki. Wykres uczenia dla tej sieci neuronowej został przedstawiony na rys. 13.

Na rys. 14 pokazano obliczone wartości wskaźników wrażliwości w procesie uczenia się sieci dla wprowadzonych wartości predyktorów podczas budowy sztucznej sieci neuronowej. Kolejność ich przedstawienia jest od najmniej do najbardziej istotnych.

Sieci	Analiza wrażliwości (MG57 RB=1)							
	Próby: Uczenie							
	LC	NC	N	LD	LE	NB	LB	LA
35.MLP 8-3-6	3,834546	2,018594	1,194772	1,084213	1,064117	1,054708	1,023436	0,998363

Rys. 14. Tabela wskaźników wrażliwości dla pierwszych badań zapalników MG-57

Przypadek nazwa	Arkusz predykcji dla DEC (MG57 RB=1) Próby: Uczenie			
	DEC Zm.zal	DEC - Wyjście 35. MLP 8-3-6	DEC - Trafność 35. MLP 8-3-6	DEC - Poziomy aktywacji 35. MLP 8-3-6
320	BP	BP	Poprawne	0,966131
323	B5	B5	Poprawne	0,853005
324	B5	B5	Poprawne	0,853005
325	B5	B5	Poprawne	0,853005
326	B5	B5	Poprawne	0,853005
327	B5	B5	Poprawne	0,853005
328	BS	BS	Poprawne	0,784566
329	B3	B5	Niepoprawne	0,853005
330	B5	B5	Poprawne	0,853005
331	B5	B5	Poprawne	0,853005
332	B5	B5	Poprawne	0,853005
333	B5	B5	Poprawne	0,853005
334	B5	B5	Poprawne	0,853005
335	BP	BP	Poprawne	0,966131
336	BP	BP	Poprawne	0,966131
337	B5	B5	Poprawne	0,853005
339	B5	B5	Poprawne	0,853005
340	B5	B5	Poprawne	0,853005
341	B5	B5	Poprawne	0,853005
342	B5	B5	Poprawne	0,853005
344	B5	B5	Poprawne	0,853005
346	BS	BS	Poprawne	0,784566
348	B5	B5	Poprawne	0,853005
349	B5	B5	Poprawne	0,853005
350	B5	B5	Poprawne	0,853005

Rys. 15. Fragment arkusza predykcji decyzji dla pierwszych badań zapalników MG-57

Dokonano także predykcji dotychczas podjętych decyzji podiagnostycznych dla wszystkich elementów próby uczącej. Fragment arkusza tych predykcji przedstawia rysunek 15, na którym widać wyróżnioną na czerwono decyzję B5, która powinna być podjęta według zbudowanej sieci neuronowej, zamiast decyzji B3 podjętej przez osobę oceniającą wyniki badań. W tym przypadku obie decyzje B3 i B5 są decyzjami pozytywnymi, różnią się jedynie okresem predykcji wynoszącym trzy lub pięć lat. Nasza zbudowana sztuczna sieć neuronowa proponuje dłuższą predykcję czasu zdatości badanego obiektu technicznego jakim jest zapalnik artyleryjski typu MG-57.

## 6. Podsumowanie

Opisano próbę zaprojektowania oraz zbudowania sztucznych sieci neuronowych dla trzech rodzajów zapalników artyleryjskich typu MG, stosowanych w nabojach artyleryjskich.

Cel pracy został w pełni osiągnięty. Określono niezbędne parametry do zbudowania prawidłowych struktur sieci neuronowych, które w efekcie finalnym doprowadziły do zbudowania sieci neuronowych o wysokich wartościach wskaźników jakościowych. Dzięki specjalistycznemu oprogramowaniu komputerowemu [4] wykonano symulację zaprojektowanych sieci, przy różnych ich topologiach i wybrano spośród otrzymanych kilkuset sieci jedną najlepszą sztuczną sieć neuronową dla każdego rodzaju zapalników artyleryjskich typu MG.

Zbudowana sieć neuronowa dla pierwszych badań laboratoryjnych zapalników typu MG-25 postaci MLP 7-3-6 charakteryzuje się najlepszymi parametrami sieci, a jej wartość jakości testowej jest na bardzo wysokim poziomie 96,36%. Podobnie sieć neuronowa postaci MLP 8-3-7 zaprojektowana dla pierwszych badań diagnostycznych dla zapalników MG-37 również charakteryzuje się najlepszymi parametrami sieci, jednakże w tym przypadku osiągnięto poziom jakości testowej 85,11%. Ostatnią zbudowaną siecią była sieć neuronowa postaci MLP 8-3-6 dla pierwszych badań diagnostycznych dla zapalników typu MG-57, która osiągnęła poziom jakości testowej na poziomie 87,40%. We wszystkich zbudowanych modelach uzyskano wysokie wartości wskaźników jakości testowej.

Zbudowane sieci neuronowe oraz ich topologia wskazują na fakt, że sieci te nie wymagają dużej liczby neuronów w warstwach ukrytych do funkcjonowania na wysokim poziomie jakościowym. W artykule, z uwagi na ograniczenia objętościowe, nie wykazano szeregu innych danych, które w sposób jednoznaczny określają i charakteryzują zbudowane sztuczne sieci neuronowe dla analizowanych zapalników typu MG.

Podsumowując, obecnie proces oceny wyników badań diagnostycznych zapalników typu MG-25, MG-37 oraz MG-57 może odbywać się za pomocą sztucznych sieci neuronowych. Wprowadzane nowe wartości predyktorów do zbudowanych sieci powodują błyskawiczną ich ocenę i automatycznie określają predykcję w postaci podjęcia właściwej decyzji podiagnostycznej oczywiście na wysokim poziomie prawdopodobieństwa podjęcia tej decyzji. Zastąpienie dotychczasowych „manualnych” modułów ocenowych przez zaprojektowane sztuczne sieci neuronowe dla poszczególnych typów zapalników artyleryjskich wydaje się więc w chwili obecnej nieodzowną koniecznością.

## **7. Literatura**

1. Amunicja wojsk lądowych. Wydawnictwo Ministerstwa Obrony Narodowej, Szefostwo Służby Uzbrojenia i Elektroniki, 1985.
2. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Biocybernetyka i inżynieria biomedyczna. Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
3. Helt P., Parol M., Piotrowski P.: Metody sztucznej inteligencji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2012.
4. Statystyka 13.1 PL – Statsoft Polska 2016 r. – oprogramowanie komputerowe.