

**DETERMINAREA PUTERII
MOTORULUI DE CONCASARE VIA
REȚEAUA NEURALĂ CU
PARAMETRII DE INTRARE
INDEPENDENȚI**

Doctor eng. Teodora Hristova, UMG "St. Ivan Rilski", Sofia, BULGARIA,
teodora@mgu.bg

Doctor ing. Ivan Minin, UMG "St. Ivan Rilski", Sofia, BULGARIA

ing. Veselin Christov, UMG "St. Ivan Rilski", Sofia, BULGARIA

REZUMAT: *Se face o încercare de a antrena o rețea neurală să determine puterea motoarelor de concasare folosind programul QwikNet 2.23. Ca rezultat, am primit rețeaua neurală antrenată cu eroarea maximă $-1,6329 \cdot 10^{-7}$. Aceasta poate fi folosită în determinarea puterii aproximative a motorului electric al morilor cilindrice, dar nu poate fi considerată ca model matematic precis.*

CUVINTE CHEIE: *rețea neurală, motor de concasare, parametrii de intrare independentă*

1. Introducere în problemă

Pentru a determina energia necesară pentru distorsiunea bucăților de minereu care pot fi folosite pentru definirea puterii motorului a mașinilor de concasare, sunt bine cunoscute patru teorii (ipoteze) de bază (Akerman and Buggati, 1982).

Considerând divizarea unui cub în multe alte cuburi mici, P. Reitinger a sugerat că efortul necesar pentru o astfel de divizie este proporțional cu suprafețele nou apărute. Ipoteza este formulată după cum urmează: "Efortul necesar în timpul distorsiunii este direct proporțional cu suprafața bucăților de minereu, obținută ca rezultat al procesului de concasare sau măcinare":

$$A_F = k_F \cdot \Delta S_F, J. \quad (1)$$

**DETERMINING THE POWER OF
CRUSHING ENGINE VIA NEURAL
NETWORK WITH INDEPENDENT
INPUT PARAMETERS**

Ph.D eng. Teodora Hristova, UMG "St. Ivan Rilski", Sofia, BULGARIA,
teodora@mgu.bg

Ph.D eng. Ivan Minin, UMG "St. Ivan Rilski", Sofia, BULGARIA

eng. Veselin Christov, UMG "St. Ivan Rilski", Sofia, BULGARIA

ABSTRACT: *An attempt is made to train a neural network to determine the power of crushing engines using program QwikNet 2.23. As a result, we have received trained neural network with maximum error - $1,6329 \cdot 10^{-7}$. It can be used in the determination of the approximate power of cylindrical mills' electric engine, but it cannot be considered an accurate mathematical model.*

KEY WORDS: *neural network, crushing engine, independent input parameters*

2. Introduction to the problem

For determining of energy necessary for distortion of ore pieces, that can be used to define motor's power of the crash machines, are well known four basic theories (hypotheses) (Akerman and Buggati, 1982). Considering division of one cube to many other small cubes, P. Reitinger suggested that the necessary work for such division is proportional to newly appearing surfaces. The hypothesis is formulated as follow: "The work necessary during distortion is in direct proportion to the surface of ore pieces, obtained as a result of the process of crushing or milling":

$$A_F = k_F \cdot \Delta S_F, J. \quad (1)$$

where:

k_F - coefficient of proportionality,

unde:

k_F - coeficientul de proporționalitate,
 J / m^2 ;

ΔS_F - suprafețe nou create în timpul
concasării, m^2 .

Bucata concasată de minereu cu diametrul
 D și cu raportul de concasare i are
următoarele suprafețe nou apărute:

$$\Delta S_F = 6 \left(\frac{D}{i} \right)^2 \frac{D^3}{\left(\frac{D}{i} \right)^3} - 6D^2 = 6^2 (i - 1), m^2. \quad (2)$$

unde:

$\frac{D}{i}$
 i este diametrul bucății concasate de
minereu, m ;

$\frac{D^3}{\left(\frac{D}{i} \right)^3}$
 $\left(\frac{D}{i} \right)^3$ - numărul de bucăți după concasare.

Atunci efortul pentru distorsiunea unei
bucăți este:

$$A_F = k_F \cdot \Delta S_F = 6k_F (i - 1) D^2, J. \quad (3)$$

Ipoieza distorsiunii Kerpitchev-Kick sună
astfel: “În cazul deformării unor corpuri
similare din punct de vedere geometric și
egale din punct de vedere fizic, munca
deformării elastice este proporțională cu
volumul corpurilor”. Astfel:

$$A_V = \frac{\sigma^2 \cdot V}{2E}, J. \quad (4)$$

Unde A_V este efortul deformării elastice a
corpurilor, J, σ - tensiunea distorsiunii
materialului, $N / m^2, V$ - volumul bucății de
minereu, m^3, E - modulul elasticității sub
presiune, N / m^2 .

J / m^2 ;

ΔS_F - newly created surfaces during the
crushing, m^2 .

Crushed ore piece with diameter D and
with ratio of crushing i has the following
newly appearing surfaces:

$$\Delta S_F = 6 \left(\frac{D}{i} \right)^2 \frac{D^3}{\left(\frac{D}{i} \right)^3} - 6D^2 = 6^2 (i - 1), m^2. \quad (2)$$

where:

$\frac{D}{i}$
 i is the diameter of crushed ore piece, m ;

$\frac{D^3}{\left(\frac{D}{i} \right)^3}$
 $\left(\frac{D}{i} \right)^3$ - number of pieces after crushing.

Then the work for distortion of one ore piece
is:

$$A_F = k_F \cdot \Delta S_F = 6k_F (i - 1) D^2, J. \quad (3)$$

The hypothesis of distortion of Kerpitchev-
Kick sounds like this: “In the case of
deformation of geometrically similar and
physically equal bodies, the work of elastic
deformation is proportional to the volume of
the bodies”. Therefore:

$$A_V = \frac{\sigma^2 \cdot V}{2E}, J. \quad (4)$$

where A_V is the work of elastic deformation
of the bodies, J, σ - tension of distortion of
material, $N / m^2, V$ - volume of ore piece,
 m^3, E - module of elasticity under pressure,
 N / m^2 .

If it is assumed that $k_V = \frac{\sigma^2}{2 \cdot E}$, than for the
coefficient of proportionality is received:

Dacă presupunem că $k_V = \frac{\sigma^2}{2.E}$, atunci pentru coeficientul de proporționalitate se primește:

$$A_V = k_V \cdot V = k_V \cdot D^3, J.$$

(5)

unde V este volumul cubului cu o latură $D; m^3$.

P.A. Robender a combinat sugestiile lui P. Reitinger și Kerpitchchev-Kick, conform cărora distorsiunea unei bucăți de minereu se face după deformarea elastică și astfel întreaga muncă din timpul concasării este suma efortului pentru deformare elastică și munca pentru crearea noilor suprafețe.

$$A = A_V + A_F = k_V \cdot D^3 + k_F \cdot D^2, J.$$

(6)

F. Bond a presupus și că întreaga muncă din timpul concasării este însumarea muncii pentru deformarea elastică și a muncii pentru crearea de noi suprafețe, dar este direct proporțională cu valoarea mediei geometrice a diametrului bucății de minereu.

$$A = A_V + A_F = k \sqrt{D^3} \cdot D^2 = k \cdot D^{2,5}, J.$$

(7)

Trebuie să subliniem că niciuna dintre aceste teorii nu descriu exact distrugerea materialelor, și aceasta din cauza faptului că ipotezele derivă din baza presupunerii pentru bucata de minereu încărcată în mod egal. Așadar, pentru calcularea mașinilor de concasare, este necesar să se introducă în plus coeficienții.

Puterea folosită de motoarele concasoarelor conice în concasarea fină și medie sunt direct proporționale cu productivitatea acestora. Valoarea medie a puterii folosite este de 50 до 75% de la instalare.

Alegerea concasoarelor se face în conformitate cu lățimea găurii de intrare și cu productivitatea lor pentru o lățime dată a eșapamentului.

$$A_V = k_V \cdot V = k_V \cdot D^3, J.$$

(5)

where V is the volume of the cube with a side $D; m^3$.

P.A. Robender combined suggestions of P. Reitinger and Kerpitchchev-Kick, that distortion of ore piece is done after elastic deformation and so the full work during the crushing is the sum of the work for elastic deformation and the work for creation of new surfaces.

$$A = A_V + A_F = k_V \cdot D^3 + k_F \cdot D^2, J.$$

(6)

F. Bond also assumed that the full work during the crushing is a sum of the work for elastic deformation and the work for creation of new surfaces, but it is in direct proportion to the average geometric value of the diameter of ore piece.

$$A = A_V + A_F = k \sqrt{D^3} \cdot D^2 = k \cdot D^{2,5}, J.$$

(7)

It has to be underlined that none of these theories do describe precisely destroying of materials, and this is due to the fact that the hypotheses are derived on the base of the assumption for evenly loaded ore piece with regular form. Therefore for computing of the crush machines it is necessary to be introduced in addition corrective coefficients.

The spend power by the motors of cone crushers for average and fine crushing is in direct proportion to their productivity. The average value of the spend power is 50 до 75% from installed.

The choice of crushers is made in accordance to the width of entrance hole and their productivity for a given width of the escapement.

$$N_{DB} \approx 0,21 \cdot n \cdot D^2, kW.$$

(8)

The cone crushers for average and fine

$$N_{DB} \approx 0,21.n.D^2, kW.$$

(8)

Concasoarele conice pentru concasarea fină și medie sunt echipate cu motoare electrice a căror putere este determinată de companiile producătoare, și o depășește considerabil, fiind obținută prin algoritmi de calcul.

Decizia acestei probleme este de a antrena rețeaua neurală, cu care se va determina mai precis puterea motoarelor electrice a concasoarelor conice pentru concasarea medie și fină.

2.Esența rețelelor neurale

Rețeaua neurală este un program matematic care constă în elemente calculate simple înrudite (neuroni). Cele două caracteristici esențiale ale rețelelor neurale sunt: abilitatea de „a învăța” și de „a generaliza”. Când „învăță”, fiecare neuron acceptă semnale de la alții (sub forma numerelor), le procesează printr-un algoritm matematic relevant și își definește activarea care este transmisă de către conexiunile exterioare către ceilalți neuroni. Fiecare conexiune are o pondere care, multiplicată cu semnalul, definește importanța (puterea). Ponderea conexiunilor este analogică cu puterea impulsurilor asociate transmise între neuronii biologici. Valoarea ponderii negative corespunde unui impuls supresiv iar cea a ponderii pozitive – unui impuls stimulant. Rețeaua neurală are un strat de intrare și de ieșire și de asemenea mai multe straturi intermediare. Pentru a dobândi precizie la un nivel mai înalt, straturile intermediare din rețeaua neuronală ar putea fi multiple. După antrenarea rețelei neuronale într-un algoritm matematic relevant, este introdus un nou vector constând în datele care nu au fost folosite pentru antrenare iar sistemul generează noi porți (Ivanova,2004).

Rețelele neurale sunt folosite pentru rezolvarea problemelor de prognoză, ca și în acest caz și au sarcina de a determina capacitatea motorului electric (Hristova și

crushing are equipped with electric motors, which power is determined by the producing companies and as it exceeds considerably this obtained by calculating algorithms.

The decision of this problem is to be trained neural network, with which it can be determined more precisely the power of electric motors of the cone crushers for average and fine crushing.

2.Essense of neural networks

The neural network is a mathematical program consisted of interrelated simple computing elements (neurons). The two most essential characteristics of the neural networks are : the ability to “learn” and to “generalize”. When “learning” every neuron accepts signals from the others (in the forms of numbers), processes them by a relevant mathematical algorithm and defines its activation which is being transmitted by the outgoing connections to the other neurons. Every connection has weight which multiplied with the signal defines the significance (power). The connections’ weight are analogical to power of the junctional impulses transmitted between the biological neurons. The negative weight value corresponds to a suppressive impulse and the positive – to a stimulating impulse. The neural network has an input and output layer and also several intermediate layers. To achieve accurateness on a higher level the intermediate layers in the neuronal network could be several. After training the neuronal network in a relevant mathematical algorithm a new array is being entered consisting of data that wasn’t used for the training and the system generates new gates (Ivanova,2004).

Neural networks are used for solving predictive problems, as in this case and has the task of determining the capacity of electric motor (Hristova and Minin, 2012). For the training of a neural network to determine the capacity of an engine is chosen universal neural network QwikNet2.23 in which array can be used

Minin, 2012). Pentru antrenarea unei rețele neurale de a determina capacitatea unui motor, se alege rețeaua neurală universală QwikNet2.23 în care vectorul poate fi folosit cu mai multe tipuri de algoritmi de antrenare.

3. Rezultate ale predării rețelei neuronale

Rețeaua neurală antrenată constă în trei straturi – stratul de intrare cu trei noduri, stratul interior cu cinci noduri și stratul de ieșire cu un nod. Intrările reprezintă parametrii geometrici ai concasoarelor: diametrul conului rulante, m; lățimea găurii de intrare, m; lățime eșapamentului, m; și ieșire: puterea motorului, kW.

Obiectele cercetării sunt mai mulți algoritmi **R prop**, **Quick prop**, **Delta-bar-delta** și **Back prop**. Problema în timpul antrenării rețelei neurale este dimensiunea mică a datelor antrenate și dimensiunea mică a intrărilor. Din acest motiv, cea mai mică eroare dă algoritmi de antrenare **Delta-bar-delta** и **Back propagation**. Prin cei mai folosiți algoritmi cu distribuție directă a erorii (Remus, 2001; Zhang, 2004) s-a antrenat o rețea, dar aceasta generalizează ieșiri cu eroare mare. Algoritmul **Back propagation** este cu distribuția opusă a celui cu eroare. Caracteristica specifică a acestui tip de algoritmi este nevoia mai multor vârste (iterații de calcul) de a dobândi antrenarea corectă a rețelei.

Pentru fiecare încercare de antrenare, se completează două calcule – pasul drept (antrenarea și obținerea activării valorilor ponderii) și pasul invers (analiza erorii în ieșirea și distribuția corecțiilor în ponderile relațiilor dintre elemente diverselor straturi). Rețelele cu distribuție opusă a erorii au o convergență joasă, așadar se antrenează mai lent. În acest caz, valoarea ponderilor se calculează cu formula:

$$\Delta w_{ij} = -\eta \frac{\partial E(t)}{\partial w_{ij}(t)} + \alpha \Delta w_{ij}(t-1)$$

(9)

several types of training algorithms.

3. Results from the neuronal network teaching

The trained neural network is consistent from three layers – input layer with three knots, a inside layer with five nodes and a output layer with one knot. The inputs represent the geometric parameters of the crushers: the diameter of the rolling cone, m; width of the entrance hole, m; width of the escapement, m; and the output: power of the motor, kW.

The objects of research are several algorithms **R prop**, **Quick prop**, **Delta-bar-delta** and **Back prop**. The problem during the training of neural network is the small size of the training data as well as the small size of the inputs. For this reason the least error gives the training algorithms **Delta-bar-delta** и **Back propagation**. Through the most often used algorithms with direct distribution of the error (Remus, 2001; Zhang, 2004) it was trained a network, but it generalizes outputs with high error. The algorithm **Back propagation** is with opposite distribution of the error one. The specific feature of this kind of algorithms is the need from more ages (computing iterations) to achieve correct training of the network.

For each training attempt are completed two calculations - right pass (training and obtaining of activation values of weights) and reverse pass (analysis of error in the output and distribution of corrections in the weights of relations between the elements of different layers). The networks with opposite distribution of the error have low convergence, therefore is trained more slowly. In this case the value of the weights is calculated with the formula:

$$\Delta w_{ij} = -\eta \frac{\partial E(t)}{\partial w_{ij}(t)} + \alpha \Delta w_{ij}(t-1)$$

(9)

where η is learner level, and α is the moment.

The correlation mistake is $2,92305 \cdot 10^{-8}$ and

Unde η este nivelul de învățare iar α este momentul.

Greșeala de corelație este $2,92305 \cdot 10^{-8}$ iar maximul este $-1,6329 \cdot 10^{-7}$, care este o valoare foarte scăzută pentru o problemă de inginerie. Pe baza acesteia, nu este nevoie de antrenarea rețelei neuronale a mai multor straturi.

În corespondență sunt ponderile prezentate în tabelul 1.

the maximum is $-1,6329 \cdot 10^{-7}$, which is very low value for an engineering problem. On account of it there is no need to train the neuronal network more intermediate layers. Correspondingly are the weights shown in table 1.

Table 1.

Neurons' weights				additional node	
1	2	3	4	5	6
0.48307	-0.315143	-0.310162	0.204397		
-0.477968	0.412331	-0.279646	0.208233		
-0.482551	-0.209769	0.270714	-0.261522		
0.185025	0.180957	0.088559	-0.393219		
0.602668	0.0610254	0.472842	-0.0250257		
0.0469074	-0.101174	0.222929	-0.206171	0.154461	-0.0587612

Tabelul 1.

Ponderile neuronilor				Nod adițional	
1	2	3	4	5	6
0.48307	-0.315143	-0.310162	0.204397		
-0.477968	0.412331	-0.279646	0.208233		
-0.482551	-0.209769	0.270714	-0.261522		
0.185025	0.180957	0.088559	-0.393219		
0.602668	0.0610254	0.472842	-0.0250257		
0.0469074	-0.101174	0.222929	-0.206171	0.154461	-0.0587612

În tabelul 2 se prezintă parametrii unei rețele neuronale „predate”.

In table 2 there are visualized the parameters of a “taught” neuronal network .

Table 2.

Parameter	Value	Parameter	Value
Epochs	1 -100000	Initial_Weight_Step_Size	0.001
Training algorithm	Online Back-Propagation (Randomize)	Momentum	0
Weight_Increase_Rate	0.1	Input_Noise	0
Weight_Decrease_Rate	0.5	Weight_Decay	
Min_Weight_Step_Size	$1 \cdot 10^{-6}$	Final_RMS_error	$2,92305 \cdot 10^{-8}$
Max_Weight_Step_Size	50	Max error	$-1,6329 \cdot 10^{-7}$

Tabelul 2.

Parametrul	Valoarea	Parametrul	Valoarea
Epocă	1 -100000	Dimensiunea inițială a pasului ponderii	0.001
Algoritm de antrenare	Propagare înapoi Online (Aleatorie)	Inerție	0
Rata de creștere a ponderii	0.1	Zgomotul de intrare	0
Rata de scădere a ponderii	0.5	Decăderea ponderii	
Dimensiunea minimă a pasului ponderii	$1 \cdot 10^{-6}$	Eroarea finală_RMS	$2,92305 \cdot 10^{-8}$
Dimensiunea maximă a pasului ponderii	50	Eroarea maximă	$-1,6329 \cdot 10^{-}$

The results of a training mistake is low and this are visualized in the next graphics. (Figure 1)




Figure 1
Figura 1

În figura 2 se prezintă o rețea neuronală predată. Culoarea conexiunilor definește greșeala și arată, de asemenea, că ieșirea este în intervalul 0 -1.

On figure 2 is it shown a taught neuronal network. The colour of the connections defines the mistake and also shows that in the exit it is in the interval 0 -1.




Figure 2.
Figura 2.

Când se testează sistemul, se obțin date mai exacte pentru a determina puterea motorului. Din păcate, testul a fost condus cu un singur număr de parametri de intrare, din lipsa datelor pentru antrenarea rețelei. Greșeala de corelație este - Final_RMS_error e $1,25905 \cdot 10^{-8}$ iar greșeala maximă este Final_Max_error $-1,13629 \cdot 10^{-8}$. În graficul următor (Figura 3) se prezintă datele pentru algoritmul de testare atunci când nu există o intrare.

When testing the system are obtained more accurate data to determine the engine power. Unfortunately the test was conducted with only one number of input parameters, for lack of sufficient data for training the network. The correlation mistake is - Final_RMS_error e $1,25905 \cdot 10^{-8}$ and the maximum mistake is Final_Max_error - $1,13629 \cdot 10^{-8}$. On the next graphics (Figure 3) there is the data of the testing algorithm when there isn't one entrance.

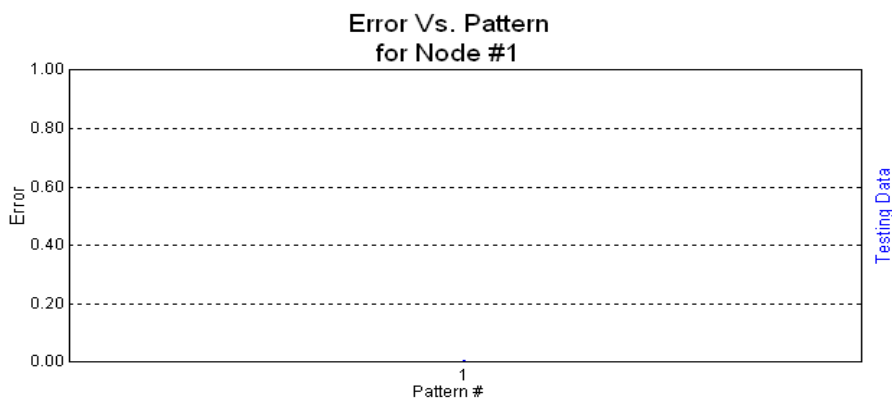


Figure 3

Următoarea figură (Figura 4) arată clar că datele de ieșire ale testului s-au obținut pentru determinarea puterii motorului fără eroare. Aceste date nu pot fi considerate finale, pentru ca este necesar să testăm rețeaua neurală antrenată cu o ieșire independentă.

The following figure (Figure 4) clearly shows that the test output data were obtained to determine the engine power without error. These data can not be considered final, because it is necessary to test the trained neural network with more independent input.




Figure 4.

Din cauza acestei probleme, se compară algoritmul rețelei neuronale antrenate și Delta-Bar-Delta, iar ponderile rezultate sunt prezentate în Tabelul 3.

Because of this problem is to compare trained neural network algorithm and Delta-Bar-Delta, as the resulting weights are shown in Table 3.

Table 3

Neurons' weights				additional node	
1	2	3	4	5	6
0.399493	-0.121421	-0.539024	0.106156		
0.114756	-0.150133	-0.417438	-0.343545		
-0.564074	-0.236451	0.174706	-0.121632		
0.212684	-0.31464	0.405536	-0.532157		
-0.263112	0.272927	-0.297903	0.106896		
-1.09015	-0.832398	-0.92423	-0.517421	-0.659932	-1.6339

Tabelul 3

Ponderile neuronilor				Nodul suplimentar	
1	2	3	4	5	6
0.399493	-0.121421	-0.539024	0.106156		
0.114756	-0.150133	-0.417438	-0.343545		
-0.564074	-0.236451	0.174706	-0.121632		
0.212684	-0.31464	0.405536	-0.532157		
-0.263112	0.272927	-0.297903	0.106896		
-1.09015	-0.832398	-0.92423	-0.517421	-0.659932	-1.6339

În tabelul 4 se prezintă parametrii unei rețele neuronale „predate”.

In table 4 there are visualized the parameters of a “taught” neuronal network .

Table 4 . Mon Mar 19 17:10:07 2012

Parameter	Value	Parameter	Value
Epochs	1 -1965069	Initial_Weight_Step_Size	0.001
Training algorithm	Delta-Bar-Delta	Momentum	0
Weight_Increase_Rate	0.06	Input_Noise	0

Weight_Decrease_Rate	0.2	Weight_Decay	1.10534e-007
DBD_Averaging_Param	0.7	Final_RMS_error	6.24498e-007

Tabelul 4 . Mon Mar 19 17:10:07 2012

Parametrul	Valoarea	Parametrul	Valoarea
Epoca	1 -1965069	Dimensiunea inițială a pasului ponderii	0.001
Algoritmul de antrenare	Delta-Bar-Delta	Inerția	0
Rata de creștere a ponderii	0.06	Zgomotul de intrare	0
Rata de scădere a ponderii	0.2	Decăderea ponderii	1.10534e-007
DBD_Parametrul mediu	0.7	Eroarea finală RMS_	6.24498e-007

În algoritmul de antrenare, rețeaua neurală se obține cu o eroare foarte scăzută (Fig. 5), dar este mai mare decât antrenarea algoritmului rețelei neurale cu distribuția înapoi a erorii.

In the training algorithm neural network is obtained with very low error (Fig. 5), but it is higher than the training of neural network algorithm with back distribution of the error.




Figure 5
Figura 5

În figura 6 se prezintă o rețea neuronală predată. Culoarea conexiunilor definește greșeala și arată, de asemenea, că ieșirea este în intervalul 0 -2.

On figure 6 is it shown a taught neuronal network. The colour of the connections defines the mistake and also shows that in the exit it is in the interval 0 -2.




Figure 6.
Figura 6.




Figure 7.
Figura 7.

Eroarea obținută în algoritmul semi-atlet rămâne constant. Până la sfârșit, algoritmul nu se schimbă (figura 7). Când se testează un sistem, apar erori, ceea ce este de așteptat. În rețeaua neurală rezultată din figura 8 se arată clar că datele brute pentru determinarea capacității motoarelor au o eroare mare – ponderile neuronii au o eroare în intervalul 1-5. Aceste date nu pot fi considerate finale, pentru că este necesar să se testeze rețeaua neurală antrenată cu ieșire mai independentă.

Error obtained in mid-athlete algorithm remains constant. By the end of the algorithm does not change (figure 7). When testing a system error occur, which is expected. On the resulting neural network of figure 8 clearly shows that the raw data for determining the capacity of engines have a high error - the weights of the neurons have an error in the range 1-5. These data can not be considered final, because it is necessary to test the trained neural network with more independent input.




Figure 8.
Figura 8.

4.Concluzii

Urmând munca de antrenare a rețelei neurale, pot fi formulate următoarele concluzii:

A. Pentru antrenarea adecvată a rețelei neurale, trebuie să existe un număr suficient de date de intrare. Se știe că o intrare vectorială prea mare duce la o eroare mai mare (Kissiova și Radulov, 2001).

4.Conclusions

Following the work of training the neural network can be made the following conclusions:

A. For proper training of neural network must have a sufficient number of input data. It is known that too large an array input leads to increased error (Kissiova and Radulov, 2001).

2. Testele ar trebui conduse nu numai cu un parametru de intrare.
3. Pentru antrenarea rețelei neurale cu mai puține intrări, ar trebui să se folosească mulțimea derivată sau alte metode.
4. Rețeaua neurală antrenată poate fi folosită pentru a prezice puterea aproximativă a motorului electric, dar poate fi folosită ca model matematic de încredere. Există date care pot fi comparate cu un alt model.
5. Determinarea puterii unui motor electric care conduce o facilitate industrială mare este o sarcină responsabilă de inginerie și o rețea neurală paralelă recomandată, folosind algoritmi standard. Cu toate acestea, rețeaua neurală este un indicator sigur al cererii de putere estimată.

BIBLIOGRAFIE:

1. Akerman U, G, Bukatii, V. Olevskii, “Manual de îmbogățire a minereurilor”, Moskva, Hedra, 1982.
2. Ivanova Mausya http://www.bam.bg/ravda2004/Ivanova_Marusya.htm
3. Kissiova Teodora, G. Radulov, E. Gegov, V. Christov “Model logic-probabilistic pentru evaluarea relației dintre poluarea mediului conform productivității și condițiile climatice în “GORUBSO ROF”, Simpozionul Internațional “Ecologia”, 2002, pp.393-401
4. Hristova, Minin, “Determinarea puterii motorului a morilor-tambur, folosind rețeaua neurală cu intrări independente, Sofia, 2012, sub press
5. Remus, W., O’Connor, M ., “Proгноза seriilor de timp ale rețelei neurale” în Armstrong, J . (Ed.) “Principii de prognoză: manual pentru cercetători și practicieni”, *Editorii Academici Kluwer*, 2001 , pp.246.
6. Zhang, P ., “Rețele neurale în prognoza business”, *Idea Group Inc. , 2004, pp.3.*

2. Tests should be conducted not only with an input parameter.
3. For training the neural network with fewer inputs should be used clustering or other methods.
4. Trained neural network can be used to predict the approximate power of the electric motor, but can be used as a reliable mathematical model. There is data to be compared with another model.
5. Determining the power of an electric motor which drives a large industrial facility is responsible engineering task and recommended parallel neural network using standard algorithms. However, the neural network is a sure indicator of the estimated power demand.

REFERENCES:

1. Akerman U, G, Bukatii, V. Olevskii, “Handbook of enrichment of ores ”, Moskva, Hedra, 1982.
2. Ivanova Mausya http://www.bam.bg/ravda2004/Ivanova_Marusya.htm
3. Kissiova Teodora, G. Radulov, E. Gegov, V. Christov “ Logical-probabilistic model for assessing the relationship between environmental pollution according to productivity and climatic conditions in “GORUBSO ROF”, Interenational Symposium “Ecology”, 2002, pp.393-401
4. Hristova, Minin, “Determination of engine power of drum mills using neural network with independent inputs, Sofia, 2012, under press
5. Remus, W., O’Connor, M ., “Neural network time-series forecasting” in in Armstrong, J . (Ed.) “Principles of forecasting: a handbook for researchers and practitioners”, *Kluwer Academic Publishers , 2001 , pp.246.*
6. Zhang, P ., “Neural networks in business forecasting”, *Idea Group Inc. , 2004, pp.3.*