

ПРОГНОЗИРАНЕ ЧРЕЗ НЕВРОННА МРЕЖА НА НАТОВАРВАНЕТО НА ДВИГАТЕЛ, ЗАДВИЖВАЩ ПОЛУАВТОГЕННА МЕЛНИЦА

Теодора Христова¹, Веселин Христов², Иван Минин³

¹ Минно-геоложки университет "Св. Иван Рилски", 1700 София, teodora@mgu.bg

² Минно-геоложки университет "Св. Иван Рилски", 1700 София, veso@mgu.bg

³ Минно-геоложки университет "Св. Иван Рилски", 1700 София, minin@dir.bg

РЕЗЮМЕ. С цел предвиждане натоварването на двигател, задвижващ полуавтогенна мелница, са обучени невронни мрежи. Направени са изводи относно възможностите за прогнозиране на работните параметри на двигателя в реално време чрез невроморфни макроси. Резултатите от изследването сочат, че многослоен персептрон с 10 - 20 възела в скритите слоеве дава най-добри резултати.

FORECASTING THE LOAD THROUGH NEURAL NETWORK ENGINE THAT POWER SAG MILL

Teodora Hristova¹, Veselin Christov², Ivan Minin³

¹ University of Mining and Geology "St. Ivan Rilski", 1700 Sofia, teodora@mgu.bg

² University of Mining and Geology "St. Ivan Rilski", 1700 Sofia, veso@mgu.bg

³ University of Mining and Geology "St. Ivan Rilski", 1700 Sofia, minin@dir.bg

ABSTRACT. In this paper, in order to predict the load on the engine which drives the SAG mill are trained neural networks. Conclusions are made concerning the opportunities to predict the performance parameters of the engine in real-time on the base of neuromorphic macros. The results of the study indicate that the multilayer perception with 10-20 knots in the hidden layers produces the best results.

Увод

В съвременните условия на управление на технологичните процеси за прогнозиране на натоварването на машините прилагането на невронни мрежи не е честа практика, особено в България. В минния бранш има експериментални опити за въвеждането им [Христов, Грабатов, 1998], но няма реално приложение. През следващите години автоматизираното електро-задвижване ще бъде обвързано с интелигентното самообучаващо се управление. Предполага се, че през 2017г. 10% от компютрите ще са обучаващи се, а не обработващи. Gartner цитира факта, че невронните мрежи се развиват и IBM има библиотека от 150 невроморфни макроси. Невронните мрежи ще се прилагат за прогнозиране на пазара, на ценовите криви, на търсенето и предлагането на стоки и специалисти. До 2024 г. поне 10% от дейностите, потенциално опасни за човешкия живот, ще изискват задължителната употреба на интелигентни самообучаващи се системи [3].

През последните години определянето на параметрите на електрическите двигатели е немислимо без изчислителни машини и програми. При определяне на мощността на двигателите на барабанните мелници се използват алгоритми, в които като входни параметри влизат размерите, ъгловата скорост и натоварването на мелниците

със смилаци тела. При повечето от тях, обаче, се оказва, че изчислената мощност обикновено е по-ниска от необходимата, което води до инсталиране на много по-мощен двигател от изчисления.

За улесняване на проектантската дейност изчислението на мощността на двигателите, задвижващи барабанните мелници, се автоматизира чрез използване на компютърни програми. Най-простата среда за това е „Microsoft EXCEL“ или „MatLab“. Въпреки въвеждането на коригиращи коефициенти изчислената мощност на двигателя отново се различава от инсталираната от завода-производител. Това най-вероятно се дължи на факта, че много от входните параметри, участващи в методиките за пресмятане на мощността на електро-двигателя на мелницата, не могат да бъдат зададени коректно и се различават от действителните. Например, при определяне на топковия товар на барабанните мелници се приема, че всички топки в барабана на мелниците са с еднакъв диаметър. От практиката обаче е известно, че при работа топките се износват и намаляват своя диаметър, което води до повишаване на плътността на смилачната среда, на нейното тегло и до повишаване на изразходваната мощност за издигане и предаване на кинетична енергия на топките.

Състояние на проблема


За решаване на този проблем са обучени невронни мрежи [Христова, Минин, 2012], чрез които да се определя по-точно мощността на електродвигателите на барабанните мелници. За обучението им се избра универсална програма QwikNet 2.23, в чийто масив могат да се използват няколко вида обучаващи алгоритъма. Създаден е масив от данни от размерите и натоварването на работеща мелница със зависими и с независими входни данни, а на изхода на невронната мрежа са зададени параметрите на двигател, работещ в реални условия. Зависими входни параметри са: дебелина на облицовката, mm и маса на топковия или прътов товар, kg, а независими един от друг са: вътрешен диаметър на барабана, m; дължина на барабана, m с обем на барабана, m³ и обороти на мелницата, min⁻¹ и относителна ъглова скорост на барабана, %. На създадените невронни мрежи са изчислени теглата на възлите, като принципът на обработване на данните за изчисление е следният: въвеждат се входните и определените по експертна оценка или взети от практиката стойности на изходни параметри. След това мрежите се обучават до определен процент грешка. Получените тегла показват степента на влияние между всички входове и изходи. След експериментите беше установено, че в невронната мрежа със зависими входни параметри, поради наличие на връзка между входните данни, прогнозирането на мощността на двигателя е с много по-ниска грешка. За

пример корелационната грешка при обучение със зависими входни параметри е (Final_RMS_error) 1.00619e-005, а максималната грешка е (Final_Max_error) - 3.76222.10⁻⁵, докато при независими входни параметри е: (Final_RMS_error) 0.383008.

Стигна се до заключение, че при обучение на невронна мрежа е необходимо да има повече входни данни, като някои от параметрите трябва да имат връзка. Това важи, обаче, когато параметрите са зависими от конструкцията на обекта, както е в случая. Така при определянето на мощността на двигателя при липса на един или два входни параметъра, ако той е зависим от останалите параметри, получената стойност ще е точна. [Христова, Минин, 2012].

В много случаи, в практиката се изисква управление на процесите съобразно с промяната на технологичните параметри в реално време. Въз основа на досегашните експерименти с невронни мрежи екипът реши да обучи нова с цел определяне на изходящата мощност на електродвигател на базата на технологични данни. По този начин при промяна на натоварването, инженерите ще имат представа за процента на неизползваемост или пренатоварване на задвижващите мощности.

За входни данни са взети технологични параметри, измерени на мелница тип SAG 8,5 x 5,3, показани на Фиг.1.



Фиг. 1. Схема на измерваните параметри

За обучение е използвана програмата Stat Soft Statistica Inc. варианти 7 и 8. Една от основните трудности при анализ на данни с невронни мрежи е подборът на вида мрежа и нейните характеристики, които са най-подходящи за конкретния анализ на данните, с които разполагаме, което е предимството на Statistica. Системата Statistica 7 притежава модул Neural Network за анализ на данни чрез невронни мрежи. В този модул е вграден инструментът Intelligent Problem Solver (IPS), който позволява на

изследвателя да даде основни параметри на 5 вида невронни мрежи и да ги изпробва върху своите данни. По време на изпробването IPS обучава десетки разновидности от избраните мрежи и накрая дава няколко с най-подходящи показатели.

В настоящия анализ са взети характеристиките на 37 обучаващи примери при различни натоварвания на обекта.

Целта е с тези данни да се намери и обучи регресионна невронна мрежа, която по зададени на нейния вход:

- L - обучаващи данни;
- В - тестващи данни,

може да определя потреблението на електроенергия на търсения обект, в случая мелница.

За да се извърши анализът в IPS се задават следните видове невронни мрежи:

- Многослоен перцептрон. (Multi-Layer Perceptron – MLP). Той има един, два или повече скрити слоеве. В нашия случай се изпробват с един и с два скрити слоя. Входът към възлите, различни от входните, е претеглена сума от изходите на невроните от предния слой, а активираща функция може да е нелинейна функция, най-често сигмоид. Използва се главно обучение с обратно разпространение, но също спрегнато градиентно спускане, квази-нютонев метод и др.

- Мрежи с радиални базисни функции (Radial Base Function - RBF). Това е трислойна мрежа с разпространение напред, в която невроните от скрития среден слой са радиални, а невроните от изходния слой са с псевдо-линейна активираща функция. Активиращата функция на радиалния неврон се нарича радиална базисна функция и зависи от разстоянието на входния сигнал до точка определена като централна точка на неврона. Най-често се избира Гаусова функция. Обучението на мрежата включва два етапа: намиране на оптимални централни точки за радиалните неврони и обучение на невроните от изходния слой. Обучаващи методи са: методи на подизвадките и на k – средно най-близък възел.

- Обобщени регресионни невронни мрежи (Generalized Regression Neural Network – GRNN). Те са модификация на вероятностните невронни мрежи. Основните им характеристики са: мрежа с два скрити слоя, с разпространение напред. Първият слой е с радиални неврони. Препоръчва се броят им да е равен на обучаващите данни, което е трудно постижимо при голям брой данни. Вторият скрит слой се състои от неврони, които са с един в повече от изходните. Задачата им е да изчислят претеглено средно от сигналите на невроните от предния слой и да го дадат на невроните от изходния слой. Обучението на този вид мрежи е сходно с това на тези с радиални базисни функции. Те работят по-бавно и изискват повече памет.


Резултати от изследването

Обучаващата извадка е от 37 данни, които се разделят по случаен принцип на 27 записа за обучение и 10 записа за тестване на намерените мрежи. В резултат от работата на IPS са намерени като най-подходящи два многослойни перцептрона (MLP) с по два скрити слоя и две невронни мрежи с радиални базисни функции (RBF), дадени в Таблица 1.

Използвани са следните методи на обучение и самообучение: BP – обучение с обратно разпространение (Back Propagation), KM – К средно (K Mean), CG – спрегнато градиентно спускане (Conjugate Gradient Descent), KN – К-ти най-близък съсед (K-Nearest Neighbor) и PI – псевдо-инвертиране (Pseudo-Invert).


Известно е, че при обучаване на невронна мрежа с повече входове се постига по-висока грешка и по-ниска достоверност на резултатите. При нарастване на броя на входовете се е повишава трениращата грешката, обаче се наблюдава намаляване на грешката при тестване. Това се дължи на силната зависимост между входните параметри т.е. на технологичните величини. Следователно за прогнозиране на консумацията на електроенергия на двигателя прилагането само на технологични величини не е достатъчно. Необходимо е да има и конструктивни параметри. Данните от изследванията са представени в таблица 1 и таблица 3.

Profile : MLP 5:5-10-7-1:1 , Index = 4
Train Perf. = 0.018914 , Select Perf. = 0.000000 , Test Perf. = 1.826073



Фиг. 2. Невронна мрежа с един изключен вход

Profile : MLP 3:3-6-4-1:1 , Index = 9
Train Perf. = 0.028206 , Select Perf. = 0.000000 , Test Perf. = 5.629580



Фиг. 3. Невронна мрежа с три входа

Поради силната зависимост на входните параметри един от друг, обучаващата програма предлага мрежи, в които е изключен един от зависимите входове. Изключването на един вход за невронна мрежа с подадени 5 входа е визуализирано на фиг. 2. При други симулации, програмата предложи мрежи с изключен вход, стойността на който се изменя в много малки граници. Това доказва, че IPS модула подсказва редукция на броя на входовете, но в нашия случай е трудно да се намери необходимият брой взаимно независими параметри фиг.3.


Бяха направени два вида симулации с различен брой на скритите възли. Установи се, че при повишаване на броя на междинните (скритите) възли грешката при обучение намалява, но има опасност от преобучение на мрежата, което би довело до увеличаване на грешката при тестване, което се доказва от таблици 1 и 2. В единия

случай е зададено, че в скритите слоеве може да има до 6 възела, а в другия до 10. В случая при 6 възела, IPS предлага като най-добри мрежи тези с два скрити слоя, което повишава броя на възлите (2x6). При 10 възела IPS предлага мрежи с един скрит слой. И в двата случая броят на възлите е почти еднакъв. Същият резултат се потвърждава с мрежите с независими параметри с три входа.

За добри резултати се избира мрежа (MLP 5:5-6-6-1:1), чиято корелация между обучаващите и получените от мрежата данни е 0.85938 и е достатъчна. При три входни параметъра тя е 0.80747 (фиг.3) за MLP 3:3-10-7-1:1 (таблица 3), което също е приемлива стойност. Кривата на реално измерените и предвидените данни е показана на фиг.4.

Таблица 1. Невронни мрежи с пет входа със зададени 10 междинни възела

Profile	Train Perf.	Test Perf.	Train Error	Test Error	Training/Members
MLP 4:4-10-8-1:1	0.027654	7.621368	0.006007	0.662251	BP100,CG20,CG59b
MLP 5:5-8-1:1	0.062686	0.875287	0.010897	0.075888	BP100,CG17c,CG1b
MLP 5:5-8-1:1	0.058421	1.317903	0.010153	0.110610	
MLP 4:4-5-1:1	0.154809	1.68229	0.026929	0.158571	BP100,CG20,CG8b
MLP 4:4-7-1:1	0.111652	1.80080	0.019506	0.162725	BP100,CG20,CG17b
MLP 4:4-8-1:1	0.093595	3.36325	0.016267	0.256430	BP100,CG20,CG4b
MLP 4:4-9-1:1	0.072481	2.87789	0.015745	0.281779	BP100,CG20,CG6
MLP 4:4-10-6-1:1	0.045059	3.78923	0.009789	0.412534	BP100,CG20,CG58b



Фиг. 4. Крива на реално измерените и предвидените данни

Таблица 2. Пет възела зададени 6 междинни възела

MLP 4:4-6-4-1:1	0.030841	1.985888	0.006700	0.209390	BP100,CG20,CG65b
MLP 5:5-6-6-1:1	0.029964	2.484024	0.006525	0.199884	BP100,CG20,CG47b

Таблица 3. Три независими входни параметри и зададени 6 и 10 междинни възела

Profile	Train Perf.	Test Perf.	Train Error	Test Error	Training/Members
RBF 3:3-6-1:1	0.656460	2.244820	0.128286	0.220023	KM,KN,PI
MLP 3:3-6-4-1:1	0.028206	5.659580	0.006128	0.390170	BP100,CG20,CG643b
MLP 3:3-10-7-1:1	0.020200	2.824885	0.004390	0.166350	BP100,CG20,CG352b
MLP 3:3-6-3-1:1	0.654349	1.44267	0.113715	0.113340	BP100,CG20,CG33b

Изводи

Предвиждането на разхода на електроенергия на двигателите според технологичните параметри чрез невронни мрежи е възможно. За постигане на по-висока точност на предвиждането са необходими технологични данни, които се променят в по-големи диапазони, т.е. при пускане и спиране на обектите, за да обхваща преходни процеси и екстремални ситуации. За по-голяма представителност и достоверност на резултатите задължително трябва да се включат и конструктивни параметри като: размер на мелницата, дебелина на облицовката или измерване на друг технологичен параметър. Следва заключението, че невронните мрежи са подходящи за прогнозиране на технологични величини.

Могат да се дадат следните препоръки за достоверно обучение на невронна мрежа с цел внедряване в реалното управление на технологичен обект:

- Търсене на технологично независими параметри.
- При наличие на голям брой зависими параметри те да се изменят в съизмерими диапазони.
- Диапазонът на изменение на обучаващата извадка да е достатъчно висок.
- Обучаващата извадка да е значително по-голяма от използваната в това изследване.
- Правилен подбор на критерии за оптималност, например разход на електроенергия, който в най-висока

степен зависи от мощността на електродвигателя, задвижващ обекта.

- От направеното изследване се вижда, че най-високи резултати дават многослойни перцептрони с един или два скрити слоя с общ брой на скритите възли от 10 до 20. При опит да се намали броят на възлите в даден слой IPS повишава броя на слоевете.

Литература

Христова Т, И. Минин, 2012, *„Определяне на мощността на двигателите на барабанните мелници чрез невронна мрежа с независими входни параметри“*, Годишник МГУ, т. 55, стр.178-181 *„Determination of the drum mills' engine capacity by using neural network with independent input parameters“*.

Христов В., Ст. Гарабитов, 1998, *„Оптимизация на задвижването на лентов транспортър с цел минимално импулсно натоварване на електродвигателя“*. Национална конференция *„Автоматика и Информатика '98“*, т.6 *„Автоматизация на минната промишленост“*, стр.92-95.

http://computerworld.bg/44737_gartner_top_10_strategicheski_it_predskazaniya/

Статията е препоръчана за публикуване от кат. „Електротехника“.