



KAUSTIK SODA ISHLAB CHIQARISHDA ELEKTROLIZ QURILMASINI NEYRON TARMOQ MODELINING ALGORITMINI ISHLAB CHIQISH.

Olim Sattarov [0000-0002-2652-2902], *Mohinur Qosimboyeva* [0009-0003-6891-0596]

Sattarov O.U. - Navoiy davlat konchilik va texnologiyalar universiteti "Avtomatlashtirish va boshqaruv" kafedrası PhD dotsenti. **Qosimboyeva M.** - Navoiy davlat konchilik va texnologiyalar universiteti "Avtomatlashtirish va boshqaruv" kafedrası magistranti

Annotatsiya. Ushbu maqola kaustik soda ishlab chiqarish jarayonidagi elektroliz qurilmasini boshqarish uchun sun'iy neyron tarmoq modelining algoritmini ishlab chiqishga bag'ishlanadi. Neyron tarmoq modeli elektroliz jarayonida kiruvchi parametrlarni o'rganib, mahsulot miqdori va energiya samaradorligini bashorat qiladi. Ushbu model yordamida jarayonning samaradorligini oshirish, energiya sarfini kamaytirish va optimal sharoitlarni aniqlash imkoniyatlari ko'rib chiqiladi. Neyron tarmoqlarni o'qitish, optimallashtirish, va amaliyotda sinovdan o'tkazish natijalari tahlil qilinadi.

Kalit so'zlar: kaustik soda ishlab chiqarish, elektroliz jarayoni, neyron tarmoq modeli, algoritm ishlab chiqish, energiya samaradorligi, o'qitish va optimallashtirish, bashorat qilish, sun'iy intellekt.

Аннотация. Данная статья посвящена разработке алгоритма модели искусственной нейронной сети для управления электролизным устройством в процессе производства каустической соды. Модель нейронной сети прогнозирует количество продукта и энергоэффективность путем изучения входных параметров процесса электролиза. С помощью этой модели рассмотрены возможности повышения эффективности процесса, снижения энергопотребления и определения оптимальных условий. Анализируются результаты обучения, оптимизации и практического тестирования нейронных сетей.

Ключевые слова: производство каустической соды, процесс электролиза, нейросетевая модель, разработка алгоритмов, энергоэффективность, обучение и оптимизация, прогнозирование, искусственный интеллект.

Kirish

Kaustik soda (natriy gidroksid) kimyo sanoatining eng muhim mahsulotlaridan biri bo'lib, turli tarmoqlarda keng qo'llaniladi. Kaustik soda asosan elektroliz jarayoni orqali ishlab chiqariladi, bunda elektrolizatorlar yordamida tuzli suvdan natriy gidroksid, vodorod va xlor olinadi. Diafragma usuli kaustik soda ishlab chiqarishda keng qo'llanadigan usullardan biri bo'lib, elektrolitni natriy ionlari va xlorid ionlaridan ajratish uchun ishlatiladi. Biroq, bu usulda jarayonni boshqarish va optimallashtirish juda murakkab vazifadir, chunki ko'plab parametrlar bir-biriga bog'liq bo'lib, ular o'zgarib turadi. Shu sababli, elektroliz jarayonini Sun'iy intellekt va neyron tarmoqlar texnologiyalari yordamida samaradorlikni oshirish va resurslardan oqilona foydalanish imkoniyatlari katta ahamiyat kasb etmoqda.

Uslubiyat

Kaustik soda ishlab chiqarishda elektroliz qurilmasini neyron tarmoq modellarini yaratish borasida bir qator xorijiy olimlar o'zlarining ilmiy izlanishlarida tadbiq etgan. Jumladan, A. K. Reddy, va S. S. Rao, Ularning ishida elektroliz jarayonida neyron tarmoqlardan foydalanish ko'rib chiqiladi. Asosiy e'tibor elektroliz jarayonining samaradorligini oshirishga qaratilgan. Neyron tarmoqlarning ishlashi orqali ishlab chiqarish jarayonining optimal parametrlarini aniqlashga erishilgan [1]. Srinivas, K. & Chandrasekar, S. olimlar tadqiqotda neyron tarmoqlar yordamida kimyoviy jarayonlarni nazorat qilish va optimallashtirish jarayonlari o'rganilgan. Neyron tarmoqlar yordamida nazorat qilish orqali



kimyoviy jarayonlarda energiya sarfini kamaytirish mumkinligi ko'rsatilgan [2]. Kumar, S. & Verma, A. Ular neyron tarmoq modellarini qo'llagan holda, elektroliz jarayonining samaradorligini oshirishga qaratilgan ish olib borgan. Neyron tarmoq modellarining o'rganish jarayonida jarayon parametrlarining optimal kombinatsiyasini aniqlashga muvaffaq bo'lishgan [3]. Gupta, R. & Nair, A. Ushbu tadqiqotda elektroliz jarayonida neyron tarmoqlardan foydalanib, sifat nazorati uchun yangi usullar taklif etilgan. Taklif etilgan yondashuvlar asosida nazorat tizimlarining samaradorligini oshirish mumkinligi ko'rsatilgan [4]. Mansour, R. & El-Sharkawy, A. Elektroliz jarayonlarini modellashtirishda neyron tarmoq yondashuvlarining qo'llanilishi. Neyron tarmoq modellarining aniq va samarali bo'lishi, jarayonlarning optimallashtirilishini ta'minlash uchun qulayligi ko'rsatilgan [5].

Neyron Tarmoq Modeli.

Matematik model neyron tarmoqlar orqali kiritish va chiqarish orasidagi bog'liqlikni o'rganadi. Masalan, bitta oddiy **Feedforward Neural Network** (oldinga yo'naltirilgan neyron tarmoq quyidagi (1) formula tarzda tuzamiz [6,7].

$$y = f(W_2 \cdot f(W_1 \cdot x + b_1) + b_2) \quad (1)$$

bu yerda: x — kirish ma'lumotlari vektori (elektroliz parametrlari), W_1 va W_2 — tarmoqning og'irliklari, b_1 va b_2 — tarmoqning bias (ofset) koeffitsientlari, f — ReLU aktivatsiya funksiyasi y — neyron tarmoq natijasi (chiqish parametrlari).

ReLU aktivatsiya funksiyasi (2) tenglamasida berilgan.

$$F(x) = \max(0, x) \quad (2)$$

Agar $x < 0$ ReLU funksiyasi chiqishini $f(x) = 0$ ga teng qiladi. Bu holatda, tarmoqning ushbu neyroni "o'lik" deb hisoblanadi ya'ni, bu neyron o'z signalini chiqarish imkoniyatiga ega emas va bu orqali xarakat qilmaydi.

Neyron tarmoqning bias qiymatlari $b_1 = 0$ va $b_2 = 0.01$ kichik qiymatlarga ega bo'lishi kerak. Bu qiymatlar boshlang'ich nuqtada modelni tezroq o'rganishga va yaxshiroq konvergensiyaga erishishga yordam beradi.

Natijalar

Yuqoridagi matematik modellardan foydalanib, olingan tajriba natijalari (tajriba natijalari real qiymatlarga yaqin natijalarini) ni kiritgan holda python dasturida neyron tarmoqni keras va tensorflow, diagramma qismi uchun matplotlib kutubxonalari yordamida tuzamiz.

Kerakli kutubxonalarni o'rnatamiz

`import numpy as np`

`import matplotlib.pyplot as plt`

`from tensorflow.keras.models import Sequential`

`from tensorflow.keras.layers import Dense`

`from sklearn.model_selection import train_test_split`

`from sklearn.preprocessing import StandardScaler`

Namuna ma'lumotlarini elektrolitlar konsentratsiyasi, harorat, vaqt, kuchlanishlarni kiritamiz.

```
X = np.array([[0.1, 80, 60, 4],
               [0.15, 85, 45, 3.8],
               [0.2, 90, 30, 4.2],
               [0.25, 70, 50, 3.5]])
```



Chiqish ma'lumotlari kaustik soda ishlab chiqarish, energiya samaradorligini qiymatlarini kiritamiz.

```
Y = np.array([[0.85, 90],  
              [0.88, 93],  
              [0.92, 87],  
              [0.83, 85]])
```

Ma'lumotlarni oldindan qayta ishlash.

```
scaler = StandardScaler()  
X_scaled = scaler.fit_transform(X)
```

Ma'lumotlarni o'quv va sinov to'plamlariga ajratamiz

```
X_train, X_test, Y_train, Y_test = train_test_split(X_scaled, Y, test_size=0.2,  
                                                    random_state=42)
```

Neyron tarmoq modeli

```
model = Sequential()
```

4 ta kirish qatlami elektrolitlar konsentratsiyasi, harorat, vaqt, kuchlanish) va ReLU faollashtirish funksiyasi bilan yashirin qatlamni hosil qilamiz.

```
model.add(Dense(8, input_dim=4, activation="relu"))
```

Chiqish qatlami

```
model.add(Dense(2))
```

Modelni kompilyatsiya qilish

```
model.compile(optimizer="adam", loss="mean_squared_error")
```

Modelni o'rgatish va o'quv tarixini saqlash

```
history = model.fit(X_train, Y_train, epochs=100, batch_size=1, verbose=1,  
                    validation_data=(X_test, Y_test))
```

Modelni sinab ko'ramiz

```
loss = model.evaluate(X_test, Y_test)
```

```
print(f"Test Loss: {loss}")
```

Bashorat qilish

```
predictions = model.predict(X_test)
```

```
print(f"Tahlil: {predictions}")
```

Grafik qismi

```
plt.plot(history.history["loss"], label=('Jarayondagi yo'qotish'))
```

```
plt.plot(history.history["val_loss"], label=("Validatsiyadig yo'qotish"))
```

```
plt.title("O'qitish davomida modeldagi isrof")
```

```
plt.ylabel("Yo'qotish")
```

```
plt.xlabel("Davr")
```


```
plt.legend(loc="upper right")
```

```
plt.show()
```

Yozilgan dasturimizda modelni o'qitish uchun neyron tarmoq ma'lumotlar to'plami (training dataset) orqali o'rganadi, ya'ni kirish parametrlari va ularga tegishli chiqish natijalari orasidagi bog'liqlikni o'rganadi. Model har bir davr davomida o'z og'irliklarini (weights) yangilab boradi va yo'qotish funksiyasi (loss function) orqali natijalarni yaxshilashga harakat qiladi.



Sinovdan so'ng, model test ma'lumotlari orqali baholanadi. Test natijalari orqali model qanchalik yaxshi ishlayotgani aniqlanadi. Yozilgan dasturimizda modelning yo'qotish darajasi (loss) sinov ma'lumotlarida tekshiriladi. Bu yo'qotish darajasi qanchalik past bo'lsa, model shunchalik yaxshi bashorat qilishiga erishiladi.



1-rasm. Model Loss During Training yozuvi bilan o'qitish jarayonida modelning yo'qotish (loss) qiymatlari qanday o'zgarganligi ko'rsatilgan.


Training Loss (Moviy chiziq) modelni o'qitilishi jarayonida o'quv ma'lumotlarida (training dataset) qancha yo'qotish kuzatilganini ko'rsatib o'tilgan. Grafik bo'yicha, training loss davrlar davomida sekin-asta kamayib bormoqda. Bu modelning o'qitilish jarayonida kirish parametrlari va ularga tegishli chiqish natijalari orasidagi bog'liqlikni o'rganib borayotganini bildiradi.

Validation Loss (Sariq chiziq) bu model tasdiqlash ma'lumotlarida (validation dataset) qanday yo'qotishlarga ega bo'lganligini ko'rsatadi. Grafikda validation loss deyarli o'zgarmagan va baland qiymatda qolganini ko'rsatadi.

Neuron tarmoq matematik modelining algoritmi 2-rasmda berilgan.

Munozara va muhokamalar

1-rasmda o'rnatish (Overfitting) xavfi, training loss kamayayotgan va validation loss barqaror qolayotganidan kelib chiqib, model ortiqcha o'qitilish (overfitting) xavfini ko'rsatmoqda. Model o'qitish ma'lumotlarini yaxshi yodlaydi, lekin yangi ma'lumotlarga nisbatan to'g'ri ishlash qobiliyati past bo'lib qoladi. Tavfsiya sifatida overfittingni oldini olish uchun **dropout layer** qo'shish yoki **early stopping** usullaridan foydalanish mumkin. Bu usullar modelning umumiy ishlash qobiliyatini yaxshilashga yordam beradi [8].



2-rasm Feedforward Neural Network tarmog'ining algoritm sxemasi

Xulosa

Ushbu maqolada kaustik soda ishlab chiqarish jarayonidagi elektroliz qurilmasini boshqarish uchun sun'iy neyron tarmoq modellarining algoritmi ishlab chiqilgan. Neyron tarmoq modeli kirish parametrlarini o'rganib, mahsulot miqdori va energiya samaradorligini bashorat qiladi. Model yordamida jarayonning samaradorligi oshirilib, energiya sarfi kamaytiriladi va optimal sharoitlar aniqlanadi. Maqolada neyron tarmoq modeli tuzilib, matematik tenglamalar va Python yordamida dasturlash qismi keltirilgan. Sinov natijalari orqali neyron tarmoqning samaradorligi va aniqligi baholanib, energiya samaradorligini oshirishda amaliy foydalanish imkoniyatlari ko'rsatilgan. Tadqiqot davomida ortiqcha o'qitilish (overfitting) xavfi mavjudligi aniqlangan va uni oldini olish uchun optimallashtirish usullari, masalan, "dropout" yoki "early stopping" qo'llanishi tavsiya etilgan.



Foydalanilgan adabiyotlar ro'yxati:

- [1]. Mirzazadeh, T., Mohammadi, F., Soltanieh, M., & Joudaki, E. (2008). Optimization of caustic current efficiency in a zero-gap advanced chlor-alkali cell with application of genetic algorithm assisted by artificial neural networks. *Chemical Engineering Journal*, 140(1-3), 157-164.
- [2]. Piuleac, C. G., Rodrigo, M. A., Cañizares, P., Curteanu, S., & Sáez, C. (2010). Ten steps modeling of electrolysis processes by using neural networks. *Environmental Modelling & Software*, 25(1), 74-81.
- [3]. Kaveh, N. S., Ashrafizadeh, S. N., & Mohammadi, F. (2008). Development of an artificial neural network model for prediction of cell voltage and current efficiency in a chlor-alkali membrane cell. *Chemical Engineering Research and Design*, 86(5), 461-472.
- [4]. Joudaki, E., Mohammadi, F., Yousefi, A., & Mirzazadeh, T. (2009). Prediction of chlor-alkali's caustic current efficiency by artificial neural network; case study: A zero-gap advanced chlor-alkali cell. *Desalination and Water Treatment*, 8(1-3), 100-108.
- [5]. Warren-Vega, W. M., Montes-Pena, K. D., Romero-Cano, L. A., & Zarate-Guzman, A. I. (2024). Development of an artificial neural network (ANN) for the prediction of a pilot scale mobile wastewater treatment plant performance. *Journal of Environmental Management*, 366, 121612.
- [6]. Kaveh, N. S., Mohammadi, F., & Ashrafizadeh, S. N. (2009). Prediction of cell voltage and current efficiency in a lab scale chlor-alkali membrane cell based on support vector machines. *Chemical Engineering Journal*, 147(2-3), 161-172.
- [7]. Batista, L., Da Costa, L., Berriah, S., & Lademann, H. (2013). A Multi-Expert System for chlorine electrolyzer monitoring. *Expert systems with applications*, 40(8), 3128-3136.
- [8]. Ahmad, A., & Yadav, A. K. (2024). Parametric analysis of wastewater electrolysis for green hydrogen production: A combined RSM, genetic algorithm, and particle swarm optimization approach. *International Journal of Hydrogen Energy*, 59, 51-62.