VAQT SERIASI BASHORATI UCHUN NEYR TARMOQLARNING SAMARALI ARXITEKTURASINI IZLASH

Abdullayeva Umida Farhadovna
E-mail: umidafarhadovna11_07g@mail.ru

Received: 25.09.2025
Revised: 26.09.2025
Accepted: 27.09.2025

Kalit so‘zlar:
Vaqt seriyasi, neyron tarmoqlar, bashorat qilish, chuqur o‘rganish, LSTM, RNN, GRU, Transformer, sun’iy intellekt, model arxitekturasi, vaqtga bog‘liq ma’lumotlar, prognozlash aniqligi.

Annotatsiya

Ushbu maqola prognoz muammosini hal qilish uchun ikkita neyron tarmoq modelini qo'llashga qiziqish uyg'otadi. Vaqt seriyalarini prognoz qilish uchun optimal Elman arxitekturasini va orqaga qarab taqsimlanmagan neyron tarmoqlarini tanlashga alohida e'tibor beriladi. Neyron tarmog'ining dizayni, prognozni ko'rib chiqish metodologiyasi va tahlili, tarmoqlarni o'qitish va sinovdan o'tkazish uchun qalqib chiquvchi usullar ham muhokama qilinadi. Neyron tarmoqlar yordamida integrallashgan MatLab muhitidan foydalanib, kerakli natijalarga erishildi.

Keywords:
time series, neural networks, forecasting, deep learning, LSTM, RNN, GRU, Transformer, artificial intelligence, model architecture, time-dependent data, prediction accuracy.

Abstract

This paper presents applying two neural network models for time series prediction problems. focused choosing optimal architecture of Elman and feedforward neural networks for time series prediction. Topics discussed include neural network design, overview methods of forecasting, sliding window method, training and testing of network, training algorithms and all results obtained with neural network toolbox in MATLAB.

Ключевые слова:
временные ряды, нейронные сети, прогнозирование, глубокое обучение, LSTM, RNN, GRU, Transformer, искусственный интеллект, архитектура модели, данные, зависящие от

Аннотация

Данная статья представляет интерес по применению двух моделей нейронных сетей для решения проблемы предсказания. Особое внимание уделяется выбору оптимальной архитектуры Эльмана и нейронных сетей без обратного распределения для прогнозирования временных рядов. Также обсуждаются дизайн нейронных сетей, методика и анализ обзора прогнозирования, всплывающих окон методов обучения и тестирования сетей. Применением интегрированной среды MATLAB с

времени, точность прогнозирования. помощью нейронных сетей получены необходимые результаты.

1. Kirish

Prognozlashning ko'plab usullari mavjud. Sxemada prognozlash usullarining umumiy ko'rinishini ko'rishingiz mumkin. Zamonaviy axborot texnologiyalari rivojlanishi bilan bir qatorda, vaqtga bog‘liq ma’lumotlarni tahlil qilish va ular asosida aniq bashoratlar berish dolzarb masalalardan biriga aylandi. Iqtisodiyot, sog‘liqni saqlash, energetika, transport va boshqa ko‘plab sohalarda vaqt seriyalari (ya’ni vaqt bo‘yicha o‘zgarib boruvchi ko‘rsatkichlar) asosida qaror qabul qilish zaruriyati tobora ortib bormoqda. Bunday holatlarda bashorat qilish sifati to‘g‘ridan-to‘g‘ri qo‘llanilayotgan algoritmlarning murakkabligi va aniqligiga bog‘liq bo‘ladi. So‘nggi yillarda sun’iy intellekt, xususan, chuqur o‘rganish (deep learning) yondashuvlari, vaqt seriyalarini prognoz qilishda yuqori samaradorlik ko‘rsatayotgani sababli keng qo‘llanila boshladi. Ayniqsa, neyron tarmoqlar, jumladan, rekurrent neyron tarmoqlar (RNN), uzun-qisqa xotirali tarmoqlar (LSTM) va Transformer arxitekturalari vaqtga bog‘liq ma’lumotlar ustida chuqur tahlil va bashoratlar qilishda o‘z afzalliklarini namoyon etmoqda.

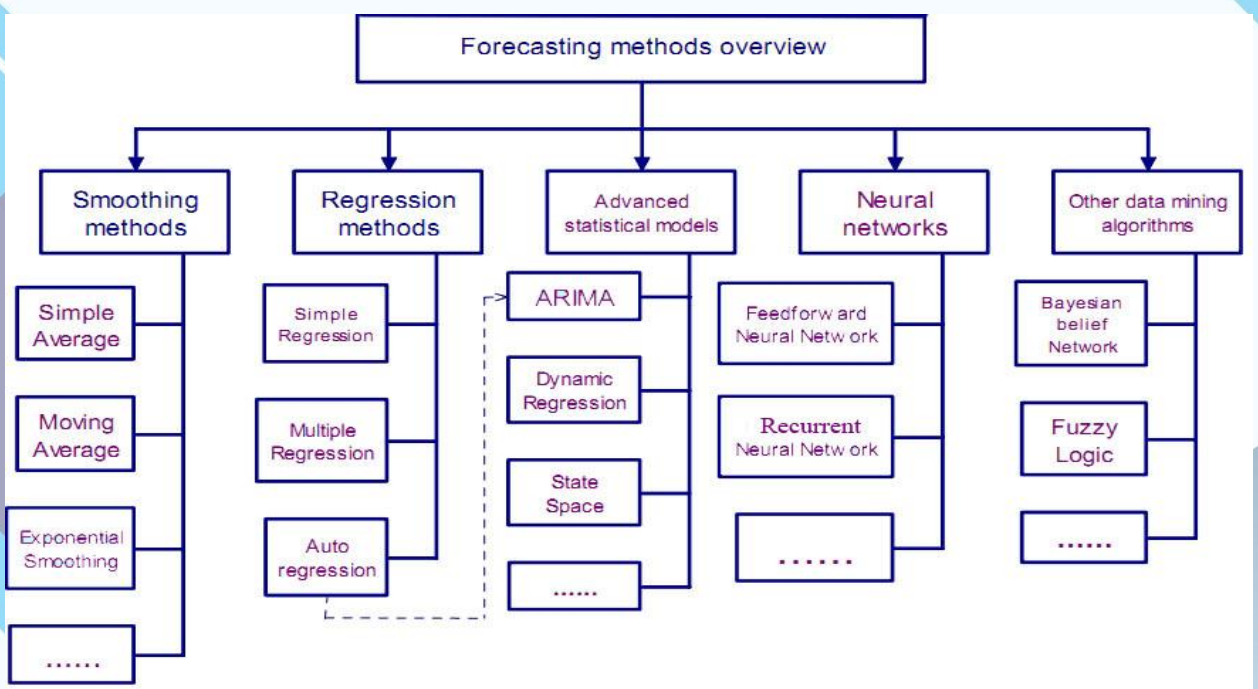

1-rasm. Prognozlash usullarining umumiy ko'rinishi

So'nggi yillarda prognozlashda sun'iy intellekt usullari keng qo'llanilmoqda, masalan, ekspert tizimlari, sun'iy neyron tarmoqlari va boshqalar.Neyron tarmoqlarning ko'plab modellari mavjud. Prognozlashda, eng ko'p ishlatiladigan oldinga yo'naltirilgan neyron tarmoqlari va Elmanning takroriy neyron tarmoqlari, kirish ketma-ketligi ustida surma oynasidan foydalanadi. Ushbu maqola Elmanning optimal arxitekturasini va vaqt seriyasini bashorat qilish uchun oldinga neyron tarmoqlarini tanlashga qaratilgan.

2. Time series prediction and sliding window.

Vaqt seriyasi - vektorlar ketma-ketligi, x(t), t=0,1,….., bu erda t o'tgan vaqtni ifodalaydi. Oddiylik uchun biz bu erda faqat skalyarlar ketma-ketligini ko'rib chiqamiz, garchi ko'rib chiqilgan usullar vektor qatorlariga osonlik bilan umumlashtirilsa. Nazariy jihatdan x t bilan doimiy ravishda o'zgarib turadigan qiymat bo'lishi mumkin, masalan, harorat, lekin amalda, har qanday jismoniy tizim uchun x vaqt oralig'ida teng bo'lgan bir qator diskret ma'lumotlar nuqtalarini berish uchun tanlanadi. Masalan, soat bo'yicha, kun bo'yicha, hafta bo'yicha, oy bo'yicha vaqt qatorlari. Oynani siljitish usuli bizga o'quv ma'lumotlar to'plamini yaratishda yordam beradi, Masalan, x(1),x(2), x(3) ……x(n) vaqt qatori vektoridir. O'lchami d ga teng bo'lgan surma oynadan foydalangandan so'ng, biz ushbu kirish-chiqish xaritalash ma'lumotlar to'plamini yaratishimiz mumkin.

kirishlar	maqsadlar
x(1), x(2),x(3),…….x(d)	*x(d+1)*
x(2),x(3),x(4)…..x(d+1)	*x(d+2)*
.	.
.	.
.	.
x(n-d-1), x(n-d),x(n-d+1)…….x(n-1)	*x(n)*

3. Feedforward va Elman takrorlanuvchi neyron tarmoq modeli.

Oldinga uzatiladigan neyron tarmog'i kirish qatlami, yashirin qatlamlar va chiqish qatlamini o'z ichiga oladi. Oldinga yo'naltirilgan tarmoqlarda barcha neyronlar va kirish birliklari oldingi neyronlar bilan bog'langan va bir xil qatlam va oldingi

qatlamda joylashgan neyronlar o'rtasida hech qanday aloqa yo'q. Elman tarmog'i takrorlanuvchi tarmoq bo'lib, u 1990 yilda Elman tomonidan taklif qilingan. Oldinga uzatish va Elman neyron tarmog'ining sxemasini 2-rasmda ko'rishingiz mumkin. unda biz prognozlashdan foydalanamiz.

Feedforward tarmoq Elman tarmoq

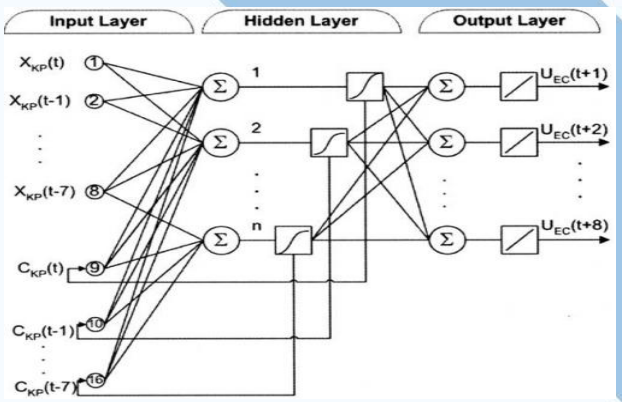

2-rasm. Feedforward va Elman neyron tarmog'i arxitekturasi

Nazariy jihatdan, ko'plab yashirin qatlamlar bo'ladi, lekin amalda odatda bitta yashirin qatlam ishlatiladi. Kirish qatlamining birliklari soni oynaning o'lchamiga teng bo'ladi. Yashirin qatlamga qancha neyron qo'yganimizni ayta olmaymiz, chunki ko'p yashirin neyronlar ko'p hisoblashadi. Shuning uchun yashirin neyronlarning optimal soni har bir ma'lumot to'plami uchun har xil bo'ladi. Faollashtirish funktsiyasi odatda oson ajratiladigan chiziqli bo'lmagan logistika funktsiyasidan keyin qo'llaniladi.

$$f(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Agar biz salbiy qiymatlarni qabul qilishi mumkin bo'lgan o'zgaruvchini prognoz qiladigan bo'lsak, faollashtirish funktsiyasi sifatida giperbolik tangensdan foydalanish yaxshidir:

$$f(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \quad (2)$$

3. Neyron tarmog'ini o'qitish va sinovdan o'tkazish

Treningda biz orqaga tarqalish usulidan foydalanamiz. Orqa tarqalish ko'p qatlamli neyron tarmoqlarni nazorat ostida o'qitishning eng oddiy va eng umumiy usullaridan biridir. O'rganishdagi asosiy yondashuv - o'rganilmagan tarmoqdan boshlash, kirish qatlamiga o'qitish naqshini taqdim etish, signallarni tarmoq orqali

o'tkazish va chiqish qatlamida chiqishni aniqlash. Ushbu natijalar maqsadli qiymatlar bilan taqqoslanadi; har qanday farq xatoga mos keladi. Ushbu xato yoki mezon funktsiyasi og'irliklarning ba'zi skaler funksiyasi bo'lib, tarmoq chiqishlari kerakli natijalarga mos kelganda minimallashtiriladi.

Biz naqsh bo'yicha o'qitish xatosini ikkita o'rtacha kvadrat (LMS) algoritmida bo'lgani kabi, o'qituvchi tomonidan berilgan kerakli natija t_k va haqiqiy chiqish z_k o'rtasidagi kvadratik farqning kirish birliklarining yig'indisi deb hisoblaymiz. qatlamli tarmoqlar.

$$J(w) = \frac{1}{2}\sum_{k=1}^{c}(t_k - z_k)^2 = \frac{1}{2}\| t - z \|^2 \quad (3)$$

Maqsad *t* va *z* mavjud va c va w uzunlikdagi tarmoq chiqish vektorlari tarmoqdagi barcha og'irliklarni ifodalaydi.

Orqaga tarqalishni o'rganish qoidasi gradient tushishiga asoslangan. Og'irliklar tasodifiy qiymatlar bilan ishga tushiriladi va keyin ular xatoni kamaytiradigan yo'nalishda o'zgartiriladi:

$$\Delta w = -\eta \frac{\partial J}{\partial w} \quad (4)$$

bu erda η o'rganish tezligi va faqat og'irlikdagi o'zgarishlarning nisbiy hajmini ko'rsatadi. Tenglamalarning kuchi. 4 ularning soddaligida: ular bizdan mezon funktsiyasini pasaytiradigan og'irlik maydonida qadam tashlashimizni talab qilishadi. Bu tenglamadan aniq. 3 mezon funksiyasi manfiy bo'lishi mumkinligi; bundan tashqari, o'rganish tezligi, patologik holatlar bundan mustasno, o'rganish to'xtatilishini kafolatlaydi. Ushbu iterativ algoritm m iteratsiyasida og'irlik vektorini olishni va uni yangilashni talab qiladi

$$w(m+1) = w(m) + \Delta w(m) \quad (6)$$

Bu erda *m* maxsus namuna taqdimotini indekslaydi.

O'quv algoritmining tugallanishi kirish va chiqishlar o'rtasida ishonchli aloqalarni o'rnatish uchun sinaptik vaznli ulanishlarni optimallashtirdi. Sinov va tekshirish bosqichida ushbu bepul parametrlar doimiy ravishda saqlanadi, shu bilan birga yangi kirishlar bir qator chiqishlarni ishlab chiqarish uchun tarmoqqa beriladi. Ushbu natijalar haqiqiy ishlab chiqarilgan natijalarga mos keladigan test ma'lumotlari to'plami bilan taqqoslanadi. Haqiqiy natija belgilangan test to'plamining chiqishidan chegara xato qiymatidan yuqori bo'lsa, treningni sozlash va neyron tarmoqni qayta o'qitish kerak.

4. Experimentlar

Ko'rishimiz mumkinki, o'quv algoritmi faqat tarmoq xatosini hisoblab chiqadi va vazn matritsasi gradient tushish usuli bilan yangilanadi, lekin tarmoqning minimal xatosi ham tarmoq konfiguratsiyasi bilan bog'liq. Feedforward va Elman-da ko'p qatlamli tarmoqlar odatda bitta yashirin qatlamdan foydalanadilar. Tarmoqning umumiy ko'rinish tuzilishi M:N:K bo'ladi, bunda M - bir nechta kirishlar yoki sirpanish oynasining o'lchami, N - yashirin neyronlar soni va K - chiqish qatlamidagi bir nechta neyronlar. Prognozlash muammolarida K 1 ga teng, ammo M va N ning optimallari har bir ma'lumot to'plami uchun har xil bo'lishi mumkin. Tajriba uchun biz evolyutsion va neyron hisoblash ma'lumotlar to'plamidan vaqt seriyasini bashorat qilish minisitesidan foydalanamiz[12]. Ushbu ma'lumotlar to'plamining qisqacha tavsifini quyidagi jadvalda topishingiz mumkin.

1-jadval. Biz tajriba sifatida foydalanilgan prognozlash uchun vaqt seriyalari ma'lumotlar to'plami

N	Ma'lumotlar to'plamining nomi	Qisqartma	Ma'lumotlar to'plami haqida	Ma'lumotlar soni
1	Quyosh nuqtalari vaqt seriyasi	STS	Bu vaqt seriyasi 1749 yil yanvaridan 1977 yil martigacha o'lchangan oyiga quyosh dog'larining o'rtacha sonini o'z ichiga oladi.	305
2	Shimoliy Atlantika tebranish vaqt seriyasi	NAO	1950 yildan 2005 yilgacha har oyda normallashtirilgan NAO indeksiga ega vaqt seriyasi	667
3	Valyuta kurslari: AQSh dollari / evro	ECU	Bu Ispaniya Markaziy banki tomonidan taqdim etilgan vaqt seriyasi bo'lib, u 1979 yil yanvaridan 2005 yil iyuligacha har oyda olingan AQSh dollarining bir evroga nisbatan o'rtacha qiymatini ko'rsatadi.	319
4	Ispaniya iste'mol narxlari indeksi	CPI	Bu Ispaniya Markaziy banki tomonidan taqdim etilgan vaqt seriyasi bo'lib, Ispaniyada 1960 yil yanvaridan 2005 yil iyunigacha bo'lgan oylik CPIni ko'rsatadi.	535
5	Ispaniyaning elektr energiyasiga bo'lgan talabi	SEED	Bu erda bizda 1959 yildan 2000 yilgacha bo'lgan har oy uchun Ispaniyada elektr energiyasiga bo'lgan talabni (GWh) ko'rsatadigan vaqt seriyalari to'plami mavjud.	492

Ushbu ma'lumotlar to'plamida oylik vaqt seriyasi ma'lumotlari mavjud, shuning uchun biz keyingi oyni, keyingi yilni yoki keyingi ikki yilni bashorat qilishimiz mumkin, ammo bu holda biz keyingi hafta yoki keyingi kun uchun prognoz qila olmaymiz.

5. Natijalar

Biz har bir ma'lumotlar to'plami uchun turli xil arxitekturaga ega bo'lgan oldinga va Elman tarmoqlarini yaratamiz. Kirish birliklari o'lchami M (1<M<18), chunki oylik vaqt seriyalari ketma-ketligi bir yil davomida takrorlanishi mumkin. Yashirin neyronlar soni uchun N, biz uni 2 kuchga oshiramiz, lekin juda yashirin neyronlar ko'proq hisoblar, shuning uchun biz 64 (21<N<26) ga qadar tekshiramiz. Biz MATLAB yordamida natijalarni olamiz. MATLAB da Neyron Network Toolbox mavjud va biz o'quv jarayonida umumlashtirishni yaxshilash uchun turli xil o'qitish funktsiyalari va ma'lumotlarni taqsimlash funktsiyalaridan foydalanamiz.

ECU ma'lumotlar to'plami uchun turli arxitekturalar uchun quyidagi natijalarni oldik:

Jadval 2. ECU ma'lumotlar to'plami uchun uzatish tarmog'ining turli arxitekturasi uchun o'rtacha MSE xatolar.

Kirish birliklarining o'lchami

Yashirin neyronlar soni	5	6	7	8	9	10	11	12
2	6,83E-04	7,57E-04	3,52E-04	9,22E-04	**3,38E-04**	1,02E-03	9,83E-04	1,17E-03
4	6,40E-04	9,34E-04	1,40E-03	8,17E-04	6,59E-04	1,09E-03	3,97E-04	8,78E-04
8	6,19E-04	1,20E-03	1,01E-03	8,17E-04	4,69E-04	7,23E-04	8,08E-04	1,16E-03
16	7,14E-04	7,88E-04	8,05E-04	9,19E-04	6,72E-04	8,41E-04	4,50E-04	8,37E-04
32	1,09E-03	7,86E-04	6,34E-04	6,66E-04	1,92E-03	9,17E-04	1,13E-03	2,05E-03
64	8,78E-04	8,37E-04	4,34E-04	1,56E-03	6,24E-04	1,69E-03	2,43E-03	1,43E-03

Biz ushbu ma'lumotlar to'plami uchun 9:2:1 ko'rinishida oldinga uzatiladigan tarmoq konfiguratsiyasi minimal xatoga erishganini ko'rishimiz mumkin va bu konfiguratsiyalar bilan o'qitilgan tarmoq bizga keyingi yil uchun quyidagi bashorat natijalarini beradi.

Jadval 3. ECU ma'lumotlar to'plami uchun Elman tarmog'ining turli arxitekturasi uchun MSE xatolarining o'rtacha ko'rsatkichi

Kirish birliklarining o'lchami

Yashirin neyronlar soni	11	12	13	14	15	16	17	18
2	2,31E-03	9,76E-03	1,09E-02	1,38E-02	1,02E-02	1,39E-02	2,25E-02	1,18E-02
4	3,38E-03	3,74E-03	4,72E-03	2,76E-03	5,39E-03	1,50E-02	**1,30E-03**	6,35E-03
8	1,40E-02	5,65E-03	2,68E-03	5,55E-03	1,50E-02	2,51E-03	4,02E-03	3,79E-03

16	2,78E-02	1,10E-02	2,94E-02	2,87E-03	7,01E-03	3,61E-02	5,44E-02	2,14E-02
32	3,54E-02	7,25E-02	4,02E-02	9,27E-02	5,59E-02	1,95E-02	1,70E-02	3,96E-01
64	4,28E-02	1,14E-01	8,87E-02	1,17E-01	3,61E-01	1,15E-01	2,45E-01	3,07E-01

Ushbu ma'lumotlar to'plamidan biz Elman tarmog'ining 17: 4: 1 konfiguratsiyasi minimal xatoga erishganini ko'rishimiz mumkin va bu konfiguratsiyalar bilan o'qitilgan tarmoq bizga keyingi yil uchun quyidagi bashorat natijalarini beradi.

Boshqa ma'lumotlar to'plami uchun biz ushbu hisob-kitoblarni qildik va biz quyidagi natijalarga erishdik

N	Ma'lumotlar to'plamining nomi	Oldinga uzatish tarmog'i uchun optimal arxitektura	MSE	Elman tarmog'i uchun optimal arxitektura	MSE
1	STS	12:4:1	3,00E+01	8:4:1	2.1058e+002
2	NAO	11:2:1	0.85	17:2:1	0.92
3	ECU	9:2:1	7.9752e-004	17:4:1	0.0015
4	CPI	17:2:1	0.0774	16:4:1	28.061
5	SEED	12:16:1	3.7969e+005	11:4:1	2.3497e+006

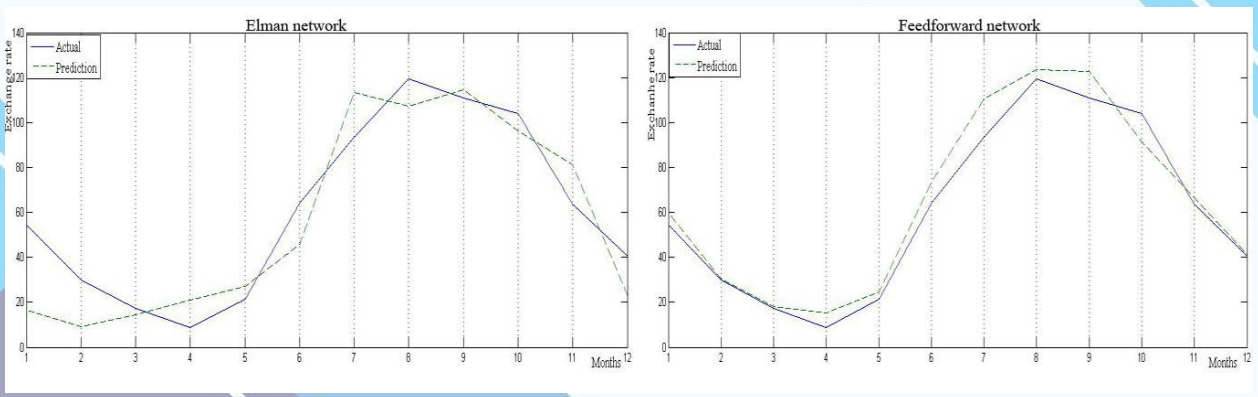

Fig.6 STS ma'lumotlar to'plami uchun Elman va Feedforward tarmoqlari bilan keyingi 12 oy uchun bashorat natijalari.

Tekshiruv hisoblangan STS ma'lumotlari 1749 yil yanvaridan 1977 yil martigacha bo'lgan quyosh dog'larining yillik sonini o'z ichiga oladi. Biz so'nggi o'n ikki oydan tashqari barcha ma'lumotlardan mashg'ulotlarda foydalanamiz, chunki biz ulardan sinovda foydalanamiz. Sinov yoki bashorat natijalari 6-rasmda ko'rsatilgan va natijalar ikki martalik model uchun yaxshi, lekin oldinga uzatish tarmog'ining natijalari Elman tarmog'idan yaxshiroqdir.

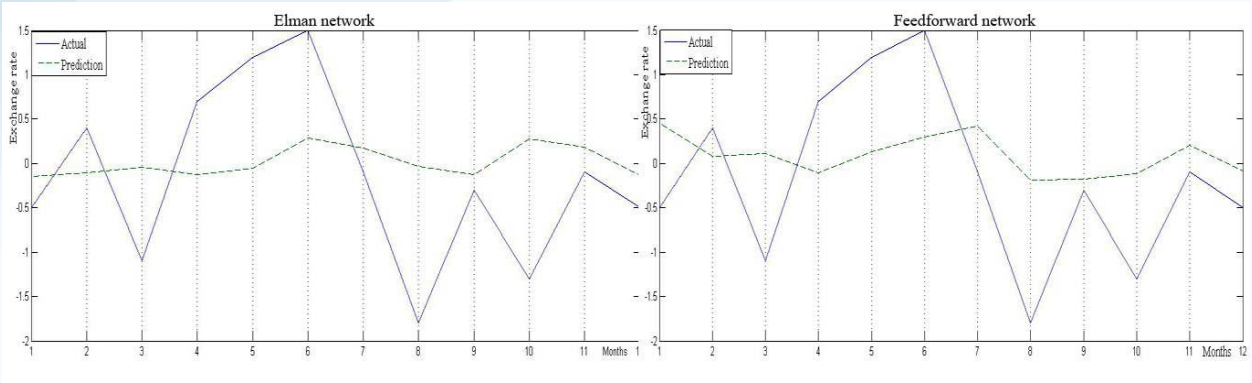

Rasm-7. NAO ma'lumotlar to'plami uchun Elman va uzatiladigan tarmoqlar bilan keyingi 12 oy uchun bashorat natijalari.

Bu ma’lumotlar to‘plami 1950-2005-yillar oralig‘ida har oyda normallashtirilgan NAO indeksiga ega bo‘lgan vaqt seriyasini o‘z ichiga oladi. Na to‘g‘ridan-to‘g‘ri, na Elman yordamida biz bu ma’lumotlar to‘plami uchun yaxshi prognozga erisha olmadik, chunki vaqt seriyalarining qiymatlari juda boshqacha va salbiy qiymatlarga ham ega, shuning uchun biz yashirin qatlamlar uchun giperbolik tangens faollashtirish funksiyasidan foydalandik. Biz umumlashtirishni yaxshilashga harakat qildik va MATLAB-dagi neyron tarmog'i asboblar qutisida turli xil o'qitish funktsiyalari, turli oldindan ishlov berish va qayta ishlash funktsiyalaridan foydalandik, ammo bashorat natijalari yaxshi emas edi. Neyron tarmoqlarni hisoblashning ushbu modellari ushbu ma'lumotlar to'plamini bashorat qilishga qodir.

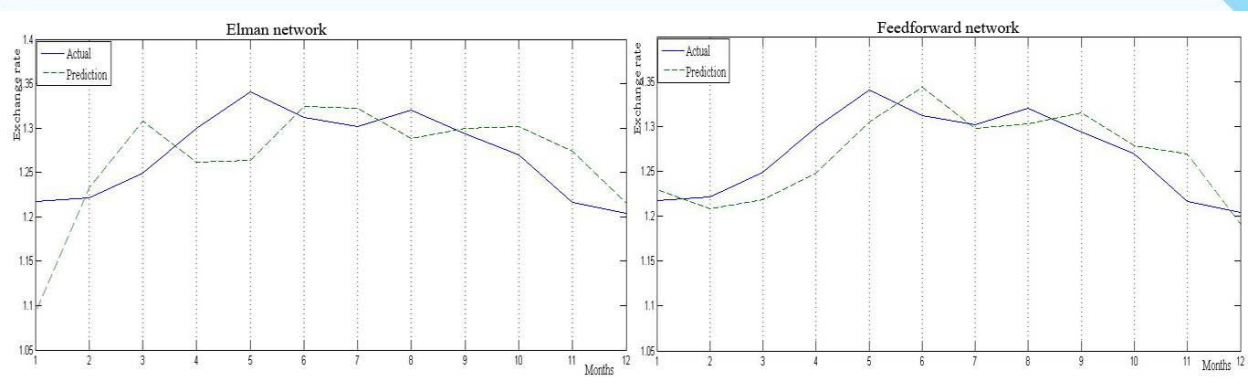

7-rasm. Elman va ECU ma’lumotlar to‘plami uchun uzatiladigan tarmoqlar yordamida keyingi 12 oy uchun bashorat natijalari

Ushbu tadqiqotda ko'rib chiqiladigan uchinchi ma'lumotlar to'plami evro va AQSh dollari o'rtasidagi almashuv kursidir. Valyuta kurslarini bashorat qilish xalqaro moliyada muhim, ammo qiyin vazifadir. Ushbu ma'lumotlar to'plami 1979 yil yanvaridan 2005 yil iyuligacha har oyda olingan AQSh dollarining bir evro kursining o'rtacha qiymatini ko'rsatadi. Neyron tarmog'ining ikki karra modelining prognoz

natijalari yaxshi. Elman tarmog'i ushbu ma'lumotlar to'plami uchun 9:2:1 arxitekturasida eng yaxshi jihozlangan va oldinga uzatish 17:4:1.

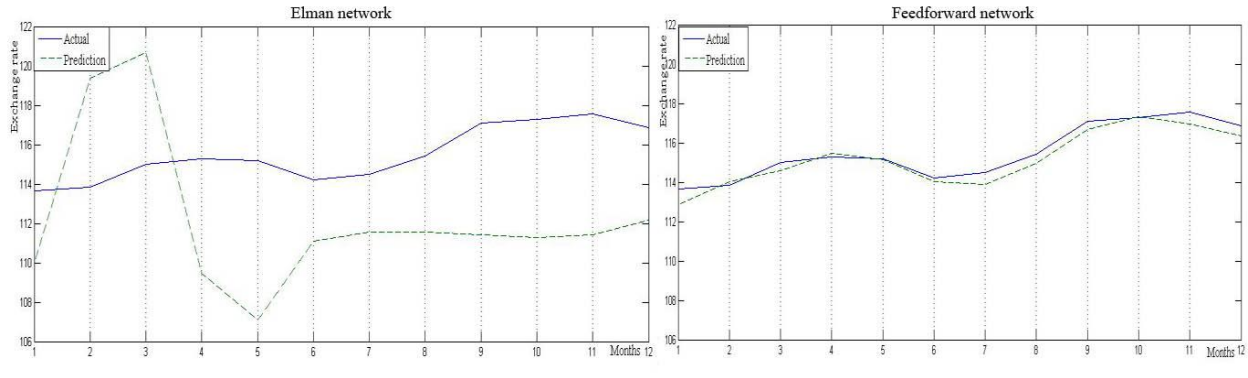

8-rasm. CPI ma'lumotlar to'plami uchun Elman va qayta yo'naltirilgan tarmoqlar bilan keyingi 12 oy uchun bashorat natijalari

Bu ma’lumotlar to‘plami Ispaniyada 1960-yil yanvaridan 2005-yil iyunigacha bo‘lgan oylik iste’mol narxlari indeksini ko‘rsatadi. Biz ushbu ma’lumotlar to‘plami uchun juda yaxshi bashorat natijalarini oldik. Buni 8-rasmda ko'rishingiz mumkin va Elman tarmog'ining natijalari yaxshi emas. Biz, shuningdek, Elman tarmog'i uchun umumlashtirishni yaxshilashga harakat qildik, lekin biz haddan tashqari moslashish muammosini hal qila olmadik. Eng yaxshi natija 17:2:1 arxitekturasida Feedforward tarmog'ida erishildi.

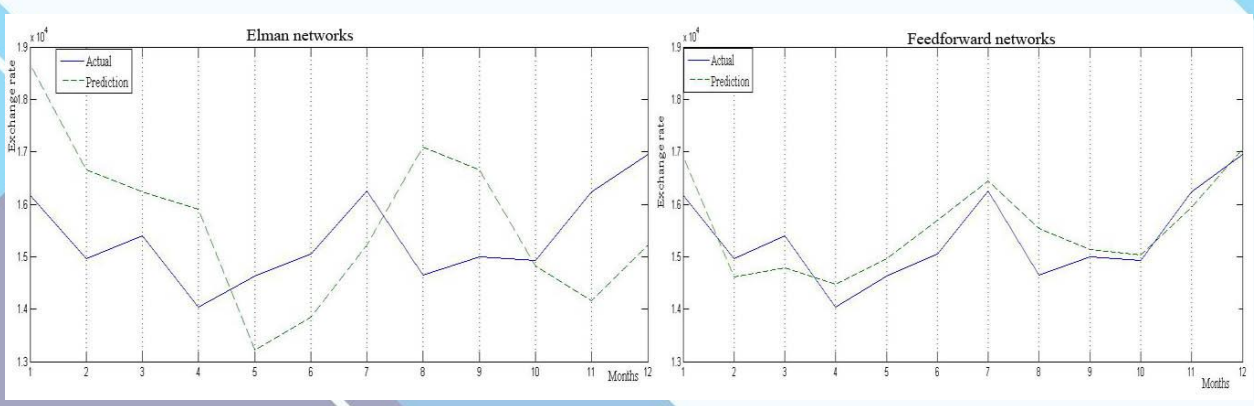

9-rasm. SEED ma’lumotlar to‘plami uchun Elman va uzatiladigan tarmoqlar yordamida keyingi 12 oy uchun bashorat natijalari

Oxirgi ma'lumotlar to'plamida Ispaniyada 1959 yildan 2000 yilgacha bo'lgan har oy uchun elektr energiyasiga bo'lgan talabni (GWh) ko'rsatadigan vaqt seriyalari to'plami mavjud. Bu ma'lumotlar to'plami uchun oldinga uzatiladigan tarmoqni bashorat qilish natijalari ham yaxshi. Eng yaxshisi 12:16:1 arxitekturasida.

Ma'lumotlar to'plamining qiymatlari rekapitulativ bo'lishi mumkin, shuning uchun oynaning kirish hajmi eng yaxshi arxitekturada o'n ikkiga teng.

Xulosa. Tadqiqotimiz shuni ko'rsatdiki, oldinga yo'naltirilgan va Elman neyron tarmoqlari vaqt qatorlarini bashorat qilish qobiliyatiga ega. Trening uchun biz neyron tarmoqlar uchun orqaga tarqalish algoritmidan foydalandik. Shuningdek, biz yashirin neyronlar soni va kirish birliklari soni (yoki toymasin oynaning o'lchami) neyron tarmog'ining ishlashiga ta'sir qilishini aniqladik, ammo yashirin neyronlar va kirish birliklari soni har bir ma'lumot to'plami uchun farq qiladi. Shuning uchun neyron tarmoqlar bilan prognozlash muammolarini hal qilish uchun biz turli xil sonli kirish nuqtalari va yashirin neyronlar bilan mashq qilishimiz kerak. Tajriba ma'lumotlar to'plamida biz sinovda faqat oxirgi 12 ma'lumotdan foydalanamiz, chunki biz faqat keyingi yilni prognoz qilmoqchimiz. Odatda testda ma'lumotlarning 15% ma'lumotlaridan foydalaniladi. Ushbu yondashuv bizga ushbu ma'lumotlar to'plami uchun tarmoqning eng yaxshi arxitekturasini tanlashda yordam beradi.

Foydalanilgan adabiyotlar ro’yxati

1. Cristopher M.Bishop. Pattern Recognition and Machine Learning. Springer Science +Business Media, LLC 2006 y.
2. Richard O. Duda, Peter E. Hart, David G. Stock Pattern Classification. John Wiley & Sons 2001 y.
3. Mehdi Khashei, Mehdi Bijari. An artificial neural network (p,d,q) model for timeseries forecasting. Expert Systems and Applications 37(2010) 479-499p.
4. Jeffery D. Martin, Yu T. Morton, Qihou Zhou. Neural network development for the forecasting of upper atmosphere parameter distributions. Advances in Space Research 36 (2005) 2480-2485p.
5. Mehdi Khashei, Mehdi Bijari. A new class of hybrid models for time series forecasting. Expert Systems with Applications 39(2012) 4344-4357
6. Zaiyong Tang, Paul A.Fishwick. Feed-forward Neural Nets as Models for Time Series Forescasting. Department of Computer & Information Sciences, University of Florida.
7. Hanh H. Nguyen, Christine W.Chan. Multiple neural networks for a long term time series forecast. Neural Comput and Applic (2004) 13: 90-98
8. Sven F. Crone, Stefan Lessmann and Swantje Pietsch. Forecasting with Computational Intelligence- an Evaluation of Support Vector Regrassion and Artificial Neural Networks for Time Series Prediction. International Joint Conference on Neural Networks, 2006 y.
9. Liang Yongchun. Application of Elman Neural Network in Short-Term Load Forecasting. International Conference on Artificial Intelligence and Computationl Intelligence 2010 y.

10. Царегородцев В. Г. Взгляд на архитектуру на требования к нейроимитатору для решения современных индустриальных задач. Всероссийская семинара «Нейроинформатика и ее приложения», Красноярск 2003.

11.Царегородцев В. Г. Оптимизация предобработки данных для обучаемой нейросети: критерии оптимальности предобработки. Международной конференции по нейрокибернетике, Растов-на-Дону, 2005

12.http://tracer.uc3m.es/tws/TimeSeriesWeb/repo.html