

## KASALLIKNI BIRLAMCHI DIAGNOSTIKASINING NEYRON TARMOQLARGA ASOSLANGAN USULLARI

*Boliyeva Dilrabo Nurbek qizi*

*Samarqand Iqtisodiyot va Servis Instituti Asissenti*

**Annotatsiya:** Sun'iy neyron tarmoqlari yuqori aniqlik bilan tashxis qo'yishi mumkin va eng muhimi, bunday texnologiya asosiy tashxis yoki kuzatuvni aniqlash uchun ishlatilishi mumkin. Ushbu maqolada bemorlar birlamchi o'z-o'zini tashxislash uchun sun'iy neyron tarmoqlarga asoslangan usul yordamida algoritim va dastur yaratish masalasi qaraladi.

**Kalit so'zlar:** EKG,RNN,NLP,LSTM,sun'iy neyron,diagnostika,tashxis,sun'iy intellect,akson,sigmoid funksiya.

Sun'iy intellekt algoritmining bir turi bo'lgan neyron tarmoqlari kasallikning asosiy diagnostikasining turli usullarida qo'llanilishi mumkin. Neyron tarmoqlardan foydalanadigan ba'zi umumiy yondashuvlar:

- Tasvir tasnifi;
- Elektrokardiogramma (EKG) tahlili;
- Genomik ma'lumotlarni tahlil qilish;
- Tabiiy tilni qayta ishlash (NLP);
- Tibbiy signallarni tahlil qilish.

Neyron tarmoqlar rentgen nurlari, KT skanerlari, MRI yoki gistopatologik slaydlar kabi tibbiy tasvirlarni turli kasalliklar toifalariga tasniflash uchun o'qitilishi mumkin. Konvolyutsion neyron tarmoqlari (CNN) odatda tasvirlarni tasniflash vazifalari uchun ishlatiladi. Ushbu tarmoqlar rasmlardan tegishli xususiyatlarni ajratib olishni va o'rganilgan naqshlar asosida bashorat qilishni o'rganadilar. Ular saraton, pnevmoniya va retinal kasalliklar kabi kasalliklarni tashxislashda muvaffaqiyat qozonishdi.

Neyron tarmoqlar EKG signallarini talqin qilishda qo'llanilishi mumkin. Takroriy neyron tarmoqlari (RNN) yoki uzoq qisqa muddatli xotira (LSTM) tarmoqlari ko'pincha ketma-ket ma'lumotlarni tahlil qilish uchun ishlatiladi. Ushbu tarmoqlar aritmiya, ishemik hodisalar yoki boshqa yurak anormalliklarini aniqlash uchun EKG signallari naqshlarini o'rganishi mumkin.

Neyron tarmoqlar genomik ma'lumotlarni tahlil qilish va kasallik tashxisi yoki prognozida yordam berish uchun ishlatilishi mumkin. Genetik ma'lumotlarning katta ma'lumotlar to'plamini o'qitish orqali neyron tarmoqlar gen ekspressiyasi, DNK ketma-ketligi yoki muayyan kasalliklar bilan bog'liq genetik variantlardagi naqshlarni o'rganishi mumkin. Ular genetik moyillikni aniqlashda, kasallik xavfini


bashorat qilishda yoki genomik profillar asosida kasalliklarni tasniflashda yordam berishi mumkin.

Neyron tarmoqlardan klinik qaydlar, bemor yozuvlari yoki tibbiy adabiyotlarni tahlil qilish uchun foydalanish mumkin. Takroriy neyron tarmoqlari (RNN) yoki transformator modellari kabi NLP usullari tuzilmagan matn ma'lumotlaridan tegishli ma'lumotlarni ajratib olishi va kasallik tashxisini qo'llab-quvvatlashi mumkin. NLP-ga asoslangan tizimlar simptomlarni aniqlash, kasallik shakllarini aniqlash yoki tibbiy adabiyotlar asosida tavsiyalar berishda yordam berishi mumkin.

Neyron tarmoqlar EEG (elektroensefalogramma), EMG (elektromyogram) yoki EKG (elektrokardiogramma) kabi turli xil tibbiy signallarni tahlil qilish uchun qo'llanilishi mumkin. Ushbu signallardagi naqshlarni qayta ishlash va tahlil qilish orqali neyron tarmoqlar epilepsiya, uyqu buzilishi yoki nerv-mushak kasalliklari kabi kasalliklarni tashxislashda yordam beradi.

Kasallikning birlamchi diagnostikasi uchun neyron tarmoqlarni muvaffaqiyatli qo'llash katta va yaxshi izohlangan ma'lumotlar to'plamini, modelni diqqat bilan o'rgatish va tekshirishni, aniqlik va umumlashtirishni ta'minlash uchun doimiy monitoringni talab qiladi. Bundan tashqari, tibbiy diagnostikada neyron tarmoqlardan foydalanish har doim to'g'ri talqin qilish va qaror qabul qilish uchun tibbiyot mutaxassislarining tajribasi bilan birlashtirilishi kerak.

Sun'iy neyron tarmog'ining asosiy tarkibiy qismi Perseptron deb nomlanuvchi sun'iy neyron hisoblanadi. Sun'iy neyron to'r – kirish va chiqishlarga ega bo'lgan qayta ishlash blokidan iborat. Aslida, biologik neyronlar dendritlar to'plami orqali o'zining uyali tanasida qayta ishlash uchun signallarni qabul qiladi va akson orqali qayta ishlangan signallarni boshqa neyronlarga yuboradi. Xuddi shunday, sun'iy neyron to'ri 2.4-rasmda ko'rsatilgandek bir nechta kirish va qayta ishlash blokidan iborat.



2.4-rasm. Biologik neyronning sun'iy neyronga taqqoslanishi  
 CHiqish qiymatlari quyidagicha formula bilan hisoblanadi:

$$y_j = f\left(\sum_{i=1}^n x_i w_{ij} - \theta_j\right) = f(w_{1j}x_1 + w_{2j}x_2 + \dots + w_{nj}x_n - \theta_j), \quad (2.1)$$

bunda

$x_i \in \{x_1, x_2, \dots, x_m\}$  kirish qiymatlari  $i \in \{1, 2, \dots, m\}$ ;

$y_i \in \{y_1, y_2, \dots, y_n\}$  chiqish qiymatlari  $j \in \{1, 2, \dots, n\}$ ;

$f(x)$  - faollashtirish funktsiyasi;

$w_{ij} \in \{w_{1j}, w_{2j}, \dots, w_{nj}\}$  og'irliklarning kirish vektori;

$\theta_j - j$ -neyron bilan bog'liq bo'lgan qaror chegarasi, bunda  $f(x) = 1$ , agar  $x_i > \theta$  va aksincha bo'lsa 0 ga teng [16].

Bitta perseptronni o'rgatish mos keladigan og'irlik va chegaralarni aniqlashni anglatadi, natijada esa ba'zi bir kirishlar perseptronga o'tkazilgandan keyin kutilgan natijaga olib keladi. Neyron chegarasini kirish bog'lanishining yana bir og'irligi kabi qaragan holda matematikani soddalashtirish yoki  $j$ -neyron uchun  $\theta = w_0 - x_0 = 1$  kirish og'irligi deb faraz qilish [17; 369–376-b.] yoki  $j$ -neyronning chegarasini  $b_j$  deb nomlanadigan siljish bilan ifodalanishi masalaning echimini topishni engillashtiradi. SHunday qilib, (2.1) tenglamasini quyidagicha qayta yozish mumkin:


$$y_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_j\right) = f\left(\sum_{i=1}^n w_{ij}x_i\right).$$

$f(x)$  funktsiya uchun amaliy sabablarga ko'ra uzlkusiz va differentsial funktsiya afzal ko'riladi, masalan, giperbolik tangens funktsiyasi ( $\tanh$ ), to'g'rilangan chiziqli blok (rectified linear unit – ReLU) va sigmoid funktsiyalar. Eng sodda tanlov sigmasimon funktsiya tanlanadi, chunki bu funktsiya chiziqli emas va hosilaviy tabiatga ega [15].

$$\sigma(x) = \frac{1}{1 + e^{-x}};$$

$$\frac{d\sigma(x)}{dx} = \sigma(x) \times (1 - \sigma(x)).$$

Sigmoid funktsiya asimptotik tabiati tufayli hech qachon 0 yoki 1 qiymat qaytarolmaydi.



2.5-rasm. Sigmoid faollashtirish funktsiyasi

Bundan tashqari, sigmasimon chiqishdan sinflash to'g'risida qaror qabul qilinishi mumkin, masalan:

$$y_j = \begin{cases} 0, & \text{agar } \sigma\left(\sum_{i=1}^n w_{ij}x_i + b_j\right) \\ 1, & \text{aks holda} \end{cases}.$$

Sigmoid funktsiyaning chiqish ma'lumotlarining chegara qiymati keyingi daraja

bilan mos holda gipertekislik sifatida ikkilik klassifikatorning echim chegarasini aniqlaydi:

$$b_j + w_{1j}x_1 + \dots + w_{nj}x_n = 0$$

Optimal perseptron sinflash masalalari sohasini chiziqli ravishda ajrata olishi mumkin bo'lgan tushunchadir [15].

Amaliy jihatdan,  $b$  siljish qiymati gipertekislikni kirish maydonida chapga va o'ngga siljitadi va  $w$  og'irliklar uni aylantiradi. Grafika terminlari bilan ifodalaganda, og'irliklar uni aylantirganda chegara gipertekislikni siljitadi. Ushbu chegara, kirish ma'lumotlari og'irliklari kabi o'rganish davomida yangilab borilishi kerak.

Perseptronni o'rganish qoidasi. Perseptronning qaror chegaralari gipertekislik bo'lib, har bir o'rganish namunasi to'g'ri tasniflanguniga qadar o'rganishni gipertekislik bo'ylab siljish jarayoni sifatida ko'rish mumkin. O'rganish jarayoni tasodifiy dastlabki og'irliklardan boshlanadi va iterativ o'rganish algoritmidan foydalangan holda kerakli natijalar olinmaguncha kam sonli bosqichlarda sozlanadi [16].

$t$  momentda tarmoq og'irliklari  $w_{ij}(t)$  bo'lsin, u holda siljish jarayoni ularning kam miqdorli  $\Delta w_{ij}(t)$  siljishiga to'g'ri keladi, shuning uchun  $t + 1$  vaqtda quyidagi og'irliklarga ega bo'lishimiz mumkin:

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta w_{ij}(t). \quad (2.2)$$

Faraz qilamiz,  $J$  perseptron blogining maqsadli chiqish signal  $\hat{y}_j$  va haqiqiy chiqish  $y_j = f\left(\sum x_i w_{ij}\right)$  bo'lsin, bu erda  $x_i$  kirishning faollashtirishlari bo'lsin.  $\Delta w_{ij}(t)$  siljitish kattaligini  $\hat{y}_j$  maqsadli chiqish va  $J$ -perseptron blogining  $y_j$  haqiqiy chiqish signali farqidan quyidagi tenglama ko'rinishida hisoblash mumkin [15]:

$$\Delta w_{ij} = \eta(\hat{y}_j - y_j)x_i,$$

bunda  $\eta$  o'rganish reytingi yoki qadam hajmini anglatib, qaror chegaralari qanchalar ravon siljiganligini aniqlaydi. (2.2) vaznni yangilash tenglamasi perseptronni o'rganish qoidasi deb ataladi va bu tenglama uchun uchta asosiy holatni ko'rib chiqamiz [16].

Agar  $\hat{y}_j - y_j = 0$  ga intiladigan  $y_j = \hat{y}_j$  bo'lsa, unda  $w_{ij}$  og'irliklar o'zgarishsiz qoladi.

Agar  $\hat{y}_j - y_j = -1$  ga intiladigan  $y_j = 1$  va  $\hat{y}_j = 0$  bo'lsa, u holda  $x_i = 1$  bo'lganda  $w_{ij}$  ni o'rganish reytingi qiymati orqali kamaytirish kerak bo'ladi:

$$w_{ij} = w_{ij} - \eta x_i.$$

Agar  $\hat{y}_j - y_j = 1$  ga intiladigan  $y_j = 0$  va  $\hat{y}_j = 1$  bo'lsa, u holda  $x_i = 1$

bo'lganda  $w_{ij}$  ni o'rganish reytingi qiymati orqali ko'paytirish kerak bo'ladi:

$$w_{ij} = w_{ij} + \eta x_i.$$

$\Delta w_{ij}$  vaznining o'zgarishi tarmoqdagi har bir  $w_{ij}$  og'irligi uchun va o'rganish to'plamidagi har bir o'rganish namunasi uchun qayta qo'llanilishi kerak. Butun o'rganishlar to'plami uchun barcha og'irliklardan bitta o'tish bitta mashg'ulot davri deb ataladi. Tarmoqning barcha chiqish ma'lumotlari barcha o'rganish shablonlariga mos kelsa o'rganish jarayoni echimga aylanadi, shuning uchun barcha  $\Delta w_{ij}$  nolga teng bo'lish holatiga keltiriladi.

Tarmoqning ikkita muhim jihatini hisobga olish kerak. Birinchisi ushbu o'rganish misollari to'g'ri tasniflanguniga qadar tarmoq o'rganilayotgan misollar to'plamidan qaror qabul qilish chegaralarini o'rganishi kerak. Ikkinchisi o'rganilgandan so'ng, tarmoq ilgari ko'rmagan test misollarini umumlashtirishi va to'g'ri tasniflashi kerak. Aslida, o'rganish va umumlashtirish o'rtasida tez-tez yuz beradigan muhim kelishuv mavjuddir [17; 369–376-b.].

Xatolikni minimallashtirib o'rganish. O'qitishning umumiy talabi - farqni minimallashtirish uchun  $w_{ij}$  tarmoq og'irliklarini  $y_j$  haqiqiy chiqishlar va  $\hat{y}_j$  maqsadli chiqishlar orasidagi farqqa minimallashtirishni sozlaydigan algoritmdir. Ushbu farqni miqdorli baholash uchun xatolik funksiyasi yoki yo'qotishlar funksiyasi  $E$  dan foydalaniladi. Neyron tarmoqlarini o'rgatish uchun ko'p hollarda foydalaniladigan miqdorli baholash funksiyalardan biri Sum Squared Error (SSE) funksiyasidir. Bu funktsiya barcha  $j$  chiqish bloklari bo'yicha yig'ilgan umumiy kvadratik xatolarini va  $p$  barcha o'rganish misollarini ifodalaydi [17; 369–376-b.]:

$$E_{SSE}(w_{ij}) = \frac{1}{2} \sum_p \sum_j (\hat{y}_{jp} - y_{jp})^2. \quad (2.3)$$

Bir necha sinflarni tasniflash masalasi uchun ko'pincha foydalaniladigan yana bir yo'qotishlar funksiyasi kross-entropiya funksiyasi deb ataladi. Agar bizda  $j$  sinfning ehtimolini ifodalovchi  $y_j$  chiqish va  $\hat{y}_j$  maqsadli chiqish mavjud bo'lsa, o'rganuvchi ma'lumotlarning butun to'plamini kuzatish ehtimoli bo'ladi, ushbu ehtimollikning salbiy logarifmini minimallashtirish orqali yo'qotishlar funksiyasi quyidagicha bo'ladi [17; 369–376-b.]:

$$E_{CE} = - \sum_p \sum_j \hat{y}_{jp} \log(y_{jp}).$$

O'rganish jarayonida ushbu xatolik funksiyasini minimallashtirishga harakat qilinadi. Kvadratik xato yig'indisini summasini minimallashtirish yo'li bilan tarmoqni o'rgatish hosilaviy xatolik tarmoqning har bir og'irligi uchun eng kamida (minimum) nolga teng bo'lishi kerakligini anglatadi [17; 369–376-b.]:

$$\frac{\partial}{\partial w_{ij}} \left[ \frac{1}{2} \sum_p \sum_j (\hat{y}_{jp} - f(\sum_j x_{ip} w_{ij}))^2 \right] = 0.$$

Agar biz  $x$  -ning berilgan qiymatini  $f(x)$  funksiyasini minimallashtirish uchun  $\Delta x$  -ga o'zgartirmoqchi bo'lsak, bajariladigan ish  $x$  -ning joriy qiymatida  $f(x)$  -ning gradientiga bog'liq bo'lib, quyidagi bilan mos keladi:

$$\Delta x = x_{new} - x_{old} = -\eta \frac{\partial f}{\partial x}, \quad (2.4)$$

bu erda  $\eta$  -ni qanchalik o'zgartirganimizni aniqlaydigan kichik musbat o'zgarmas va  $\partial f / \partial x$  hosilasi qaysi yo'nalishga harakat qilish kerakligini bildiradi. (2.4) tenglamasi iteratsiyasi orqali  $f(x)$  funktsiya minimal darajaga tushishda davom etadi. Ushbu iteratsion protsedura gradient tushishni minimallashtirish deb nomlanadi [17; 369–376-b.].

Ushbu g'oya,  $E(w_{ij})$  qiymati “etarlicha kichik” bo'lib qolmagunga qadar  $w_{ij} \leftarrow w_{ij} + \Delta w_{ij}$  og'irliklariga bir qator kichik yangilanishlarni qo'llashda beriladi. Buning uchun yo'qotishlarlar funksiyasini eng yaxshi shaklda kamaytirish uchun og'irlik vektori o'zgarishi kerak bo'lgan yo'nalishni aniqlashimiz kerak. Bunga  $w_{ij}$  og'irliklarini o'zgartirishning  $E$  yo'qotishlarlar funksiyasi gradientiga ta'sirini bilish orqali erishish mumkin. Og'irlikni gradientga qarshi kichik qadamlarda qayta sozlash orqali yo'qotishlar funksiyasi og'irliklar oralig'ida harakat qiladi va gradientlar bo'ylab minimal qiymatga tushadi [17; 369–376-b.].

Neyron tarmoqlar algoritmlari, xususan, konvolyutsion neyron tarmoqlari (CNN) odatda tibbiy tasvirlarni tasniflash uchun ishlatiladi. CNN turli xil tibbiy tasvirlash vazifalarida mukammal ishlashni namoyish etdi. Tibbiy tasvirlarni tasniflash uchun ishlatiladigan ba'zi mashhur neyron tarmoq arxitekturalari:

AlexNet: AlexNet 2012-yilda ImageNet Large Scale Visual Recognition Challenge tanlovida g'olib chiqqanidan so'ng mashhur bo'lgan CNN arxitekturasi ilg'or arxitekturalaridan biri edi. U bir nechta konvolyutsion qatlamlardan, maksimal birlashtiruvchi qatlamlardan va to'liq bog'langan qatlamlardan iborat. AlexNet yaxshi natijalar bilan tibbiy tasvirlarni tasniflash vazifalariga moslashtirilgan va qo'llanilgan.

VGGNet. VGGNet o'zining soddaligi va samaradorligi bilan mashhur bo'lgan chuqur CNN arxitekturasi. U bir xil tuzilishga ega bo'lib, kichik retseptiv maydonlarning bir nechta konvolyutsion qatlamlari va undan keyin maksimal yig'ish qatlamlari mavjud. VGG16 va VGG19 kabi VGGNet o'zgarishlari tibbiy tasvirlarni tasniflash vazifalari uchun keng qo'llanilgan.

ResNet. ResNet (qoldiq neyron tarmog'i) juda chuqur neyron tarmoqlarda



yo'qolib borayotgan gradient muammosini hal qilish uchun qoldiq ulanishlar kontsepsiyasini taqdim etdi. ResNet arxitekturalari chuqurroq modellarni o'rgatish imkonini beruvchi qoldiq bloklarni o'z ichiga oladi. ResNet50 yoki ResNet101 kabi ResNet o'zgarishlari tibbiy tasvirni tasniflash vazifalarida ajoyib natijalarga erishdi.

InceptionNet. InceptionNet (shuningdek, GoogLeNet nomi bilan ham tanilgan) turli darajadagi tasvir tafsilotlarini olish uchun bir nechta filtr o'lchamlarini parallel ravishda ishlatadigan "Inception" modullari kontsepsiyasini taqdim etdi. Ushbu arxitektura model murakkabligi va hisoblash samaradorligini muvozanatlashtirishga qaratilgan. InceptionNet modellari tibbiy tasvirlarni tasniflash vazifalariga muvaffaqiyatli qo'llanildi.

DenseNet. DenseNet arxitektura bo'lib, u har bir qatlamni har bir qatlamga oldinga uzatish usulida ulash orqali kuchli xususiyatlardan qayta foydalanishga qaratilgan. DenseNet zich ulanishlarni taqdim etadi, gradient oqimini osonlashtiradi va tarmoq orqali samarali ma'lumot tarqalishini ta'minlaydi. DenseNet modellari tibbiy tasvirlarni tasniflash ilovalarida va'da berdi.

EfficientNet. EfficientNet yaqinda CNN arxitekturasi bo'lib, tarmoq chuqurligi, kengligi va ruxsatini optimallashtirish orqali yanada aniqlik va samaradorlikka erishishga qaratilgan. U model o'lchami va unumdorligi o'rtasidagi muvozanatni muvozanatlash uchun murakkab masshtablash usulidan foydalanadi. EfficientNet turli xil tasvirlarni tasniflash vazifalarida, jumladan, tibbiy tasvirlashda eng zamonaviy ish faoliyatini namoyish etdi.

Shuni ta'kidlash kerakki, bular tibbiy tasvirlarni tasniflashda qo'llaniladigan CNN arxitekturasi bir nechta misollari. Tadqiqotchilar ko'pincha ushbu arxitekturalarni maxsus tibbiy ko'rish vazifalari va ma'lumotlar to'plamiga mos ravishda o'zgartiradilar va moslashtiradilar. Bundan tashqari, katta umumiy tasvir ma'lumotlar to'plamida (masalan, ImageNet) oldindan o'rgatilgan modellar tibbiy tasvirlarga sozlangan transferli o'rganish o'rganilgan xususiyatlardan foydalanish va tibbiy tasvir tasnifida ish faoliyatini yaxshilash uchun keng tarqalgan amaliyotdir.

Neyron tarmoqlar elektrokardiogramma (EKG) signallarini talqin qilishda samarali qo'llanilgan. EKG signallari yurakning elektr faolligini ushlaydi va turli yurak kasalliklarini tashxislash uchun qimmatli ma'lumotlarni taqdim etishi mumkin. Neyron tarmoqlar EKG signalini tahlil qilishda qo'llaniladigan ba'zi usullarni qisqacha qarab chiqaylik.

Aritmiya tasnifi. Aritmiya tasnifi uchun neyron tarmoqlar, xususan, takroriy neyron tarmoqlari (RNN) va uzoq qisqa muddatli xotira (LSTM) tarmoqlari odatda qo'llaniladi. Ushbu tarmoqlar ketma-ket EKG ma'lumotlarini tahlil qilishi va atriyal fibrilatsiya, qorincha taxikardiyasi yoki bradikardiya kabi turli xil aritmiya bilan bog'liq bo'lgan naqshlarni o'rganishi mumkin. Modellar katta izohli ma'lumotlar to'plamida o'qitiladi va EKG signallarini turli ritm sinflariga aniq tasniflashi mumkin.

Ishemiyanani aniqlash. Neyron tarmoqlari yurak ishemiyasini aniqlashda yordam beradi, bu yurak mushaklariga qon oqimining etarli emasligini anglatadi. Ishemik hodisalar EKG signalining ST segmentidagi o'zgarishlarni tahlil qilish orqali aniqlanishi mumkin. Neyron tarmoqlar ishemik o'zgarishlar bilan bog'liq bo'lgan naqshlarni o'rganishi va ishemik hodisalarni avtomatlashtirilgan aniqlash va bashorat qilishni ta'minlashi mumkin, bu esa miyokard infarkti kabi holatlarni tashxislashda yordam beradi.

QT oralig'ini tahlil qilish. EKGdagi QT oralig'i qorincha depolarizatsiyasi va repolyarizatsiyasining davomiyligini ifodalaydi. QT oralig'ining uzayishi aritmiya xavfining oshishi bilan bog'liq bo'lishi mumkin. Neyron tarmoqlar EKG signallaridagi QT oralig'ini tahlil qilishi va anormalliklarni aniqlashga yoki torsades de pointes kabi yurak hodisalari xavfini bashorat qilishga yordam beradi.

Yurak urish tezligining o'zgaruvchanligi (HRV) tahlili. HRV ketma-ket yurak urishlari orasidagi vaqt oralig'idagi o'zgarishlarni anglatadi. U avtonom asab tizimi va yurak salomatligi haqida tushuncha beradi. Neyron tarmoqlar EKG signallaridan olingan HRV naqshlarini tahlil qilishi va vegetativ funktsiyani baholash, xavf omillarini bashorat qilish yoki yurak urish tezligining buzilishi yoki vegetativ disfunktsiya kabi holatlarni tashxislashda yordam berishi mumkin.

Shovqinni olib tashlash va shovqinni yo'qotish: EKG signallari ko'pincha turli omillar, jumladan, harakat artefaktlari yoki boshqa elektr qurilmalarining shovqinlari tufayli yuzaga keladigan shovqinlarga sezgir. Neyron tarmoqlarni EKG signallaridan shovqinni olib tashlash va yozuvlar sifatini oshirish, keyingi tahlil va izohlashning aniqligini oshirish uchun o'rgatish mumkin.

Shuni ta'kidlash kerakki, EKG signallarini talqin qilishda neyron tarmoqlarni qo'llash katta va yaxshi tanlangan ma'lumotlar to'plamini, EKG signallarini ehtiyotkorlik bilan qayta ishlashni va ekspert izohlari bilan tekshirishni talab qiladi. Bundan tashqari, neyron tarmoq modellarini klinik amaliyotga integratsiyalash to'g'ri talqin qilish va qaror qabul qilishni ta'minlash uchun tibbiyot mutaxassislari bilan hamkorlikda amalga oshirilishi kerak.

### **Adabiyotlar**

1. Blumenthal, D., & Tavenner, M. (2010). The "meaningful use" regulation for electronic health records. *New England Journal of Medicine*, 363(6), 501-504.
2. Esteva, A., et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017. 542(7639), 115-118.
3. Coudray, N., et al. Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. *Nature Medicine*, 2018. 24(10), 1559-1567.



4. Attia, Z. I., et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *The Lancet*, 2019. 394(10201), 861-867.

5. Haenssle, H. A., et al. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of Oncology*, 2018. 29(8), 1836-1842.