

Dağınıq Skleroz Xəstəliyinin İdarə Olunmasında Süni İntellekt Texnologiyalarının Tətbiqi

Fatimə Əliyeva¹, Aytən Məmmədbəyli², Rəna Şirəliyeva³

^{1,2}Azərbaycan Tibb Universiteti, Bakı, Azərbaycan

³Ə.Əliyev adına Azərbaycan Dövlət Həkimləri Təkmilləşdirmə İnstitutu, Bakı, Azərbaycan

¹faliyeva2@amu.edu.az, ²ayten2001@gmail.com, ³rana.shiraliyeva@gmail.com

Xülasə— Dağınıq skleroz (DS) klinik təzahürlərinin heterogenliyi ilə seçilən xroniki autoimmün xəstəlikdir. Son illərdə süni intellekt (Sİ) metodlarının, xüsusilə maşın öyrənməsi (ML) və dərin öyrənmə (DL) texnikalarının tətbiqi DS xəstəliyinin idarə edilməsində yeni imkanlar yaratmışdır. Bu tədqiqat çərçivəsində DS xəstəliyinin diaqnostika, müalicə və proqnozunda Sİ imkanları araşdırılmışdır. Araşdırma nəticəsində məlum olmuşdur ki, Recurrent Neural Networks modelləri zaman ardıcılığını effektiv modelləşdirərək xəstəliyin uzunmüddətli proqnozlaşdırılmasında üstünlük göstərir. Random forest və XGBoost modelləri relaps riskinin və proqressiya ehtimalının yüksək dəqiqliklə qiymətləndirilməsini təmin edir. MindGlide platforması MRT təhlilini sürətləndirir, CDSS sistemləri isə fərdi müalicə qərarlarının optimallaşdırılmasına şərait yaradır. Biomarker əsaslı modellər subklinik mərhələdə xəstəliyin aşkarlanmasına yeni imkanlar açır. Nəticə etibarilə, klinik, radioloji və molekulyar məlumatların multimodal integrasiyasına əsaslanan hibrid model yanaşmaları DS xəstəliyinin fərdiləşdirilmiş idarə olunması və erkən müdaxilə strategiyalarının inkişaf etdirilməsi üçün perspektivli yanaşma təklif edir.

Açar sözlər— *Dağınıq skleroz, Süni intellekt, Maşın öyrənməsi, Dərin öyrənmə, MindGlide, hibrid modellər, diaqnostika, proqnoz.*

I. GİRİŞ

Dağınıq skleroz (DS) mərkəzi sinir sisteminə iltihab, demiyelinizasiya və neyrodegenerasiya ilə xarakterizə olunan, gedişatı zamanla dəyişən və proqressivləşən xroniki autoimmün xəstəlikdir [1]. Patologiya zamanı sinir impulslarının ötürülməsi zəifləyir və ya tamamilə pozulur ki, bu da müxtəlif funksional pozulmalara gətirib çıxarır. Dünyada 2.8 milyondan çox insan bu xəstəlikdən əziyyət çəkir və gənc insanlarda (20-40 yaş) travmadan sonra əlilliyin ikinci ən yayılmış səbəbidir.

DS əsasən 20-40 yaşlarında aşkarlanır və qadınlarda kişilərə nisbətən iki dəfə çox rast gəlinir. Xəstəliyin etiologiyası multifaktorialdır-genetik meyillilik, virus infeksiyaları (xüsusilə Epşteyn-Barr virusu), ətraf mühitin təsiri (məsələn, D vitamini çatışmazlığı və siqaret istifadəsi) xəstəliyin inkişafında mühüm rol oynayır.

DS-un klinik təzahürləri çoxşaxəlidir: sensor, motor pozulmalar, görmədə dəyişikliklər, yorğunluq, çanaq orqanlarının disfunksiyası, koqnitiv geriləmə və psixi simptomlar xəstədən xəstəyə fərqlənir. Bu cür heterogenlik

diaqnostikani çətinləşdirir və xəstəliyin proqnozunu mürəkkəbləşdirir.

Son illərdə süni intellekt (Sİ) alqoritmlərinin tətbiqi DS-un diaqnostikası, müalicəsi və proqnozlaşdırılmasında yeni imkanlar yaratmışdır [2].

Bu texnologiyalar klinik və radioloji məlumatları analiz etməklə xəstəliyin daha erkən mərhələdə aşkar olunmasına və fərdi müalicə planlarının tərtibinə şərait yaradır. Genetik, biokimyəvi və görüntü əsaslı dataların Sİ –lə integrasiyası sahəsində daha səmərəli idarəetmə modelləri formalaşmaqdadır [3].

II. PROBLEMİN QOYULUŞU

DS diaqnostika və müalicəsi bir sıra ciddi çətinliklərlə müşayiət olunur. Xəstəliyin müxtəlif formalarının və simptomlarının zənginliyi, onun erkən mərhələdə aşkar olunmasını və düzgün müalicə strategiyasının seçilməsini çətinləşdirir. Mövcud tibbi yanaşmalar çox vaxt xəstəliyin fərdi gedişatını və residiv ehtimalını doğru şəkildə təxmin etməkdə kifayət qədər effektiv olmur. Aşağıdakı əsas problemlər qeyd olunmalıdır:

- Simptomların dəyişkənliyi: eyni xəstəlik fərqli xəstələrdə müxtəlif formada özünü göstərə bilər ki, bu da standart diaqnostik protokollarının tətbiqini çətinləşdirir.
- Gec diaqnostika: Xəstələrin çoxu ilkin mərhələdə qeyri-spesifik əlamətlərlə müraciət etdiklərindən diaqnoz qoyulması aylarla, bəzən illərlə gecikir.
- Proqnoz qeyri-dəqiqliyi: DS-un gələcək gedişatını, əlillik dərəcəsinin necə dəyişəcəyinin, remissiyanın müddətini təxmin etmək olduqca çətinidir.
- Radioloji məlumatların subyektiv təhlili: MRT və digər görüntüləmə nəticələrinin qiymətləndirilməsi həkimin təcrübəsindən asılıdır və bu təhlil dəqiq olmalıdır.
- Real vaxtlı qərar dəstəyi sistemlərinin olmaması: Toplanan məlumatları klinik təcrübədə həkimlərin sürətli və dəqiq qərar qəbul etməsini təmin edən texnoloji alətlər hələ geniş tətbiq olunmur.

III. PROBLEMİN HƏLLİ

A. DS-un effektiv diaqnostikası və müalicəsi üçün Sİ əsaslı yanaşmalar

DS-un effektiv diaqnostikası və müalicəsi üçün Sİ əsaslı yanaşmalar mərhələli şəkildə tətbiq oluna bilər.

I mərhələ. Məlumatların toplanması və Strukturlaşdırılması: kliniki nevroloji simptomlar, EDSS balın hesablanması, radioloji göstəricilər (MRT-də lezyon sayı, lokalizasiyası və kontrastlanma göstəriciləri) və xəstəliyin anamnezi (başlanma yaşı, hücumların sayı, remissiya müddəti).

Verilənlərin vahid formaya gətirilməsi üçün onların ilkin emalı həyata keçirilir, istifadəçinin müdaxiləsi ilə bazadakı müxtəlif tipli verilənlər eyni tipə (float) gətirilir.

II mərhələ. Analiz aparmaq üçün vacib göstəricilərin seçilməsi və etikətlənmə: Sİ vasitəsilə verilənlərdən müxtəlif modellərin qurulması üçün lazım olanlar seçilir və analizin istiqaməti təyin olunur.

III mərhələ. Modellərin qurulması və öyrədilməsi:

Recurrent Neural Networks (RNN): Bu model xəstəliyin gedişatında zaman ardıcılığı olan məlumatları təhlil etməyə imkan verir [4]. Xəstənin əvvəlki və indiki göstəricilərinin məlumatları əsasında gələcəkdə əlillik səviyyəsinin artıb artmayacağını proqnozlaşdırmağa bilər.

Random Forest və XGBoost: Bu ansambl modelləri müxtəlif dəyişənlərin birgə təsirini qiymətləndirməklə xəstəliyin residivləşmə ehtimalını və progressiv formaya keçid riskini yüksək dəqiqliklə müəyyən edə bilər [5, 6].

MindGlide platforması: MRT görüntülərini avtomatik interpretasiyası, lezyonların aşkarlanması və beyin atrofiyasının ölçülməsi sahəsində yüksək sürət və dəqiqliklə nəticələr verir. Sistem 10 saniyədən az müddətdə nəticələri analiz edərək real vaxtlı qərar dəstəyini təmin edir [7, 8].

Kliniki qərar dəstək sistemləri: bu sistemlər pasiyentin kliniki və radioloji məlumatlarını təhlil edərək fərdi müalicə sxemləri hazırlayır. Həkimlər üçün relaps riski, alternativ müalicə və dərman seçimləri ilə bağlı qərar verməyə dəstək olur [9].

Biomarker əsaslı modellər (Support vector machines (SVM) və Logistik regression (LM)): Sİ alqoritmləri ilə integrasiya olunan biomarker göstəriciləri (NfL, GFAP, sitokinlər, oliqoklonal bandlar və s.) subklinik dəyişikliklərin aşkarlanmasını təmin edir.


Bu yanaşma erkən diaqnoz və profilaktik müdaxilələr üçün yeni imkanlar yaradır [10,11].

Multimodal analiz: kliniki, radioloji və molekulyar məlumatlarının birlikdə modellərə daxil edilməsi daha dəqiq və etibarlı nəticələrin əldə olunmasını təmin edir. Bu yanaşma individual tibbi qərarların qəbulunu asanlaşdırır [12-14].

B. Müxtəlif Sİ modellərinin müqayisəsi

Yuxarıda qeyd olunan Sİ modellərinin Area Under Curve (AUC) müqayisəsi göstərir ki, RNN modelləri EDSS

proqnozlaşdırılmasında RF modellərini üstələyir (AUC=0.91 qarşı 0.84). Random Forest və SVM modelləri isə güclü proqnostik göstəricilərə malikdirlər (şəkil 1).



Şəkil 1. Sİ modellərinin AUC göstəricilərinin müqayisəsi.

RNN modelləri DS zamanla dəyişən gedişatını (məsələn, EDSS göstəricilərinin artması) təxmin etmədə daha uyğundur, LSTM və GRU variantları ilə uzunmüddətli relaps proqnozunda istifadə ola bilər.

Random Forest modeli statik və ya toplanmış məlumat bazasında (məsələn, kliniki əlamətlər, MRT və biomarker dataları) relaps riskini qiymətləndirə bilər, lakin xəstəliyin zaman üzrə dəyişməsinə modeləşdirə bilmir. Əgər çox dəyişkən və kompleks əlaqəli böyük datasetlər varsa (məsələn, minlərlə kliniki dəyişən və biomarker), XGBoost relaps və ya progressiv gedişata keçid riskini daha yaxşı proqnozlaşdırır. Burada problem modelin hiperparametrlərinin düzgün tənzimləmək lazımdır.

MindGlide platforması MRT analizləri sürətli və obyektiv analiz edir, lakin platforma kliniki praktikaya tam integrasiya olunmalıdır ki, nəticələr praktik qərarlarla birləşdirilə bilsin. Kliniki qərar dəstək sistemlərinin funksiyası sistemə daxil olan məlumatların doğruluğundan asılıdır və fərdi müalicə planı qurmaqda həkimə yardımçı olur.

Biomarker əsaslı modellərdə isə əsas problem tələb olunan məlumatların əldə edilməsində çətinlikdir və daha bahalı müayinə üsullarının tələb olunmasıdır. Müxtəlif Sİ modellərinin DS xəstəliyin müalicəsində üstünlükləri cədvəldə göstərilmişdir (cədvəl 1).

C. Hibrid modellərin tətbiqi

Hibrid model—iki və ya daha çox fərqli metod və ya alqoritmın birləşdirilməsi yolu ilə qurulan bir modeldir. Məqsəd hər bir metodun güclü tərəflərindən istifadə edərək, dəqiqliyi artırmaq, təhlili dərinləşdirmək və məhdudiyyətləri kompensasiya etməkdir. Hibrid modellərin ənənəvi modellərdən bir sıra üstünlükləri var (cədvəl 2).

CƏDVƏL 1. DS ZAMANI Sİ MODELƏRİNİN MÜQAYISƏSİ

Model	İstifadə	Üstünlük	Məhdudiyyət
RNN	DS zamanı gedişatın zamanla proqnozu	Zaman ardıcılıqlarını effektiv modeləşdirir; uzunmüddətli tendensiyaları öyrənir	Uzun təlim vaxtı, çoxlu data tələb edir, overfitting riski
RF	DS proqressiya ehtimalı	Asan interpretasiya olunur, müxtəlif dəyişənlərlə yaxşı işləyir	Zaman ardıcılığın nəzərə alınmır, kompleks dəyişənlər üçün bəzən məhdudiyyət yaradır
XGBoost	DS relaps riski	Yüksək dəqiqlik, çatışmayan məlumatlara qarşı tolerantlıq	Parametr requlyasiyası çətindir, çox böyük data olan zaman daha effektivdir
MindGlide	MRT nəticələrinin avtomatik analizi	Sürətli (10 san), yüksək dəqiqlik	Klinik integrasiyaya ehtiyac, standart protokollara uyğunlaşdırılmalıdır
CDSS	Fərdi müalicə planlarının hazırlanması	İndividual tibbi qərar dəstəyi, alternativ müalicə yolları dəstəyi	Qərarlar daxil olunmuş datanın keyfiyyətindən asılıdır, səhv nəticə riski var
Biomarker əsaslı modellər	Erkən diaqnostika	Subklinik mərhələdə diaqnoz, profilaktik müdaxilə imkanı	Bahalıdır, klinik praktikaya tam integrasiya olunmayıb

CƏDVƏL 2. ƏNƏNƏVİ VƏ HİBRİD MODEL MÜQAYISƏSİ

Model	Ənənəvi	Hibrid
Verilənlər	Bir növ (məsələn sadəcə klinik)	Müxtəlif məlumatlar (klinik, radioloji, molekulyar)
Dəqiqlik	Orta və dəyişkən	Yüksək və stabil
Tətbiq	Məhduddur	Daha praktiki və çevikdir

DS xəstəliydə istifadə oluna biləcək hibrid modellər cədvəldə təsvir olunmuşdur (cədvəl 3).

CƏDVƏL 3. DS ÜÇÜN HİBRİD MODEL NÜMUNƏLƏRİ


Hibrid model kombinasiyası	İstifadə məqsədi	Təsvir
CNN+RNN	MRT və zaman ardıcılığının birləşməsi	CNN ilə MRT görüntü xüsusiyyətləri çıxarılır, sonra RNN ilə zaman ardıcılığı modeləşdirilir
RF + Biomarker Analizi	Statik kliniki və biomarker əsaslı relaps proqnozu	Biomarker səviyyələri ilə RF relaps riskini qiymətləndirir
XGBoost+ Time-Aware LSTM	Xəstəlik gedişatının zamanla inkişaf proqnozlaşdırılması	XGBoost ilə dəyişənlər seçilir, sonra LSTM ilə zaman seyası modeləşdirilir
MindGlide+CDSS	MRT və Kliniki qərar dəstəyi	MindGlide görüntü təhlilini edir, CDSS müalicə təkliflərini optimallaşdırır
Multi Modal Fusion Networks	Kliniki+radioloji+ biomarker integrasiyası	Bütün məlumat növləri eyni modeldə birləşdirilir, individual proqnoz və müalicə taktikası müəyyən edilir

D. DS üçün hibrid model hazırlanması

Model 3 əsas hissədən ibarətdir: CNN bloku (MRT görüntülərindən əsas göstəriciləri çıxarır), LSTM bloku (klinik zaman seriyası məlumatını modeləşdirir), XGBoost (dəyişənlər əsasında əlavə proqnoz gücü verir və son nəticə üçün birləşdirir (şəkil 2)).

Modelin üstünlükəri:

- Multimodal təhlil: kliniki, radioloji və molekulyar məlumatların sintezi daha dəqiq nəticələr verir
- Zaman aspekti: LSTM bloku xəstəliyin dinamikasını zamanla izləyir
- Erkən diaqnostika və müdaxilə: Biomarker blokları subklinik dəyişiklikləri vaxtında aşkar etməyə imkan verir
- Fərdi qərar dəstəyi: Model çıxışları fərdi müalicə strategiyalarının qurulmasına kömək edə bilər.



Şəkil 2. Hibrid model arxitekturası.

IV. NƏTİCƏ

Tədqiqat çərçivəsində müxtəlif Sİ modelləri- RNN, Random Forest, XGBoost, kliniki qərar dəstək sistemləri, MindGlide platforması və biomarker əsaslı modellər müqayisə edimişdir. Alınan nəticə:

- RNN modelləri, xüsusilə LSTM və GRU strukturları, xəstəliyin uzunmüddətli zamanla dəyişənləri əsasında əhəmiyyətli səviyyəsinin dəyişilməsini (məsələn EDSS ballarının artımını) proqnozlaşdırmada yüksək performans (AUC=0.91) nümayiş etdirir. Bu da xəstəliyin zamanla dəyişən gedişatının daha dəqiq öyrənilməsində RNN modellərinin üstünlüyünü təsdiq edir

- RF və XGBoost modelləri relaps ehtimalını və xəstəliyin proqressiv formaya keçid riskinin qiymətləndirilməsində effektivdir. RF modeli müxtəlif dəyişənlərin birgə təsirini asanlıqla modeləşdirə bilir. XGBoost isə böyük və kompleks

dataseti idarə etməkdə yüksək dəqiqlik və optimallaşdırma bacarığı göstərir.

- MindGlide platforması MRTməlumatlarının sürətli (10 san az) və obyektiv təhlilini təmin edərək kliniki qərarların daha sürətli və dəqiq qəbuluna imkan yaradır.

- Kliniki qərar dəstək sistemləri fərdi xəstə məlumatları əsasında müalicə strategiyalarının formalaşdırılmasında mühüm rol oynayır.

- Biomarker əsaslı modellər (NfL, GFAP, oliqoklonal bandlar və digər molekulyar markerlər əsasında) sublinik dəyişikliklərin aşkarlanmasında və erkən diaqnostikanda əvəzolunmaz imkanlar təqdim edir.

Tədqiqat həmçinin göstərdi ki, multimodal analiz yanaşmaları-hibrid modellər –DS xəstəliyinin daha etibarlı və dəqiq proqnozlaşdırılması üçün effektiv yanaşmadır. Bu üsul fərdi səviyyədə xəstəlik gedişatını optimallaşdırılması və individual tibbi qərarların qəbulunu əhəmiyyətli dərəcədə asanlaşdırır.

Əldə olunan nəticələr əsasında təklif olunan CNN+LSTM+XGBoost əsaslı hibrid model arxitekturası DS xəstəliyi diaqnozu və proqnozu üçün yeni bir mərhələ təşkil edə bilər.

Nəticədə, deyə bilərik ki, Sİ və hibrid modellərinə əsaslanan yanaşmalar DS xəstəliyinin idarə olunmasında yeni bir dövrün başlanğıcıdır.

Gələcəkdə daha böyük və multimodal datasetlər üzərində aparılan tədqiqatlar, modellərin klinik praktikaya effektiv integrasiyası və səhvlərə tolerant sistemlərin yaradılması bu sahənin inkişafı üçün əsas istiqamətlər olacaqdır.

ƏDƏBİYYAT

- [1] A. W. Wingerchuk and B. G. Weinshenker, "Multiple sclerosis: epidemiology, genetics, classification, natural history, and clinical outcome measures," *Neuroimaging Clinics of North America*, vol. 18, no. 4, pp. 585–596, 2008.
- [2] L. Rocca, M. Battaglini, G. Benedict et al., "Brain MRI atrophy quantification in MS: From methods to clinical application," *Neurology*, vol. 95, no. 8, pp. 336–348, 2020.
- [3] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [4] M. Eitel, L. Soehler, and B. Ploner, "Artificial intelligence in multiple sclerosis research: a systematic review," *Multiple Sclerosis Journal*, vol. 27, no. 6, pp. 795–813, 2021.
- [5] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [6] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, San Francisco, CA, USA, 2016, pp. 785–794.
- [7] D. Valverde, A. Oliver, and X. Llado, "Medical imaging in multiple sclerosis: Advances and machine learning applications," *Frontiers in Neuroscience*, vol. 15, p. 755012, 2021.
- [8] M. Fartaria, A. Bonnier, R. Meuli, "Automated detection of multiple sclerosis lesions using convolutional neural networks with multi-sequence MRI," *NeuroImage: Clinical*, vol. 17, pp. 511–518, 2018.
- [9] A. Kucyeski, B. Monohan, and A. Gauthier, "Applications of machine learning to the analysis of multiple sclerosis clinical data," *Frontiers in Neurology*, vol. 11, p. 620, 2020.
- [10] D. Bzdok and A. Meyer-Lindenberg, "Machine learning for precision psychiatry: Opportunities and challenges," *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, vol. 3, no. 3, pp. 223–230, 2018.
- [11] A. Z. Brain, "Biomarkers in Multiple Sclerosis: Current Status and Future Prospects," *Frontiers in Neurology*, vol. 10, p. 1230, 2019.
- [12] H. R. Cross and A. L. Salter, "Artificial intelligence for multiple sclerosis management," *Multiple Sclerosis Journal*, vol. 27, no. 5, pp. 581–588, 2021.
- [13] E. Louapre, M. Edan, and B. Bodini, "Artificial intelligence in the diagnosis and prognosis of multiple sclerosis: Current status and future perspectives," *Multiple Sclerosis and Related Disorders*, vol. 65, p. 104004, 2022.
- [14] Y. Zhang, J. Wang, and W. Wu, "Hybrid deep learning models for early prediction of multiple sclerosis progression," *IEEE Access*, vol. 10, pp. 125634–125646, 2022.