

डीप लर्निंग तकनीक का उपयोग करते हुए भ्रूण वृद्धि प्रतिधारण की भविष्यवाणी : एक समीक्षा

Prediction of Fetal Growth Retention using Deep Learning Techniques: A Review

कौलेश्वर प्रसाद¹, एम.वी. पद्मावती², पवन कुमार पटनायक³

Kauleshwar Prasad¹, M.V. Padmavati², Pawan Kumar Patnaik³

¹Assistant Professor, Bhilai Institute of Technology, Durg, Chhattisgarh, India

²Professor, Bhilai Institute of Technology, Durg, Chhattisgarh, India

³Associate Professor, Bhilai Institute of Technology, Durg, Chhattisgarh, India

¹kauleshwarprasad@gmail.com, ²vmetta@gmail.com, ³pawanpatnaik37@gmail.com

सारांश

गर्भावस्था के दौरान कुछ ऐसी जटिलताएं जैसे संक्रमण, अवरुद्ध प्रसव और अत्यधिक रक्तस्राव उत्पन्न होती है जिसके कारण बच्चे या बच्चे की मां की मृत्यु की संभावनाएं होती हैं। गर्भावस्था से संबंधित बीमारियों और मौत के रोकथाम के लिए उचित प्रसव की प्रक्रिया एवं निगरानी प्रणाली की आवश्यकता है। यह शोध पत्र गर्भावस्था के दौरान भ्रूण के स्वास्थ्य की स्थिति पर केंद्रित है। प्रसव के समय उत्पन्न अधिकतर जटिलताएं भ्रूण मृत्यु का कारण बन जाती हैं। भ्रूण के उचित विकास के लिए यह आवश्यक है कि प्रसव की जटिलताओं के उत्पन्न होने के पूर्व ही जोखिम की भविष्यवाणी कर दी जाए। कन्वॉल्यूशन न्यूरल नेटवर्क (CNN) एक डीप लर्निंग तकनीक है जिसमें अल्ट्रासोनोग्राफी से इमेज फीचर्स उद्धरण किया जाता है। इसके पश्चात टेक्स्ट फीचर्स और इमेज फीचर्स को मिलाकर एक नया फीचर तैयार किया जाता है। भ्रूण वृद्धि प्रतिशोध की भविष्यवाणी के लिए बहुत सारे मशीन लर्निंग एल्गोरिथ्म (Machine Learning Algorithm) जैसे डिसीजन ट्री (Decision Tree), लॉजिस्टिक रिग्रेशन (Logistic Regression), रैंडम फॉरेस्ट (Random Forest), सपोर्ट वेक्टर मशीन (Support Vector Machine) का इस्तेमाल किया जा सकता है। हमारा उद्देश्य भ्रूण वृद्धि प्रतिशोध (Fetal Growth Retardation) की भविष्यवाणी से संबंधित किए गए शोध की समीक्षा करना है। अभी तक किए गए शोध में या तो केवल टेक्स्ट फीचर्स या इमेज फीचर्स का इस्तेमाल करके भ्रूण वृद्धि प्रतिशोध की भविष्यवाणी वाले पत्रों की समीक्षा की गई है। इस समीक्षा पत्र में टेक्स्ट फीचर्स और इमेज फीचर्स दोनों प्रकार के शोध पत्रों का इस्तेमाल किया गया है।

Abstract

The pregnancy related complications such as infections, obstructed labor and excessive bleeding directly contribute to either diseases for mother or baby or maternal deaths. For the prevention of pregnancy related diseases and deaths there is proper delivery process and monitoring system for the labor with appropriate action-based findings. This research focuses on condition of fetal health during pregnancy. Most complications during pregnancy lead to fetus death. Safe pregnancy period by predicting risk levels before the occurrence of complications encourage proper fetal growth. Convolution Neural Network (CNN) is a

deep learning technique which is used for the extraction of image features from ultrasonography images. After that text features and image features are combined to get final features. In order to predict the occurrence of fetal growth retardation (FGR) any of the machine learning algorithms like Decision Tree, Logistic Regression (LR), Random Forest (RF) and Support Vector Machine (SVM) may be used. The objective is to produce review research done on the prediction of fetal growth retardation (FGR). Research to date has used either only text features or image features to predict fetal growth retardation. Research paper with both text features and image features have been used in this review paper.

मुख्य शब्द : भ्रूण वृद्धि प्रतिशोध, मशीन लर्निंग एल्गोरिदम, डिसीजन ट्री, सपोर्ट वेक्टर मशीन, लॉजिस्टिक रिग्रेशन, रैंडम फॉरेस्ट, कॉन्वोलुशन न्यूरल नेटवर्क

Keywords : Fetal growth retardation, machine learning algorithm, Decision Tree, Support Vector Machine, Logistic Regression, Random Forest, Convolution Neural Network

1. परिचय :

इक्कीसवीं सदी की शुरुआत में डेटा नेटवर्किंग, सांख्यिकी और कम्प्यूटेशनल विज्ञान के क्षेत्रों में डीप लर्निंग ने अहम भूमिका निभाई है। हाल में यह देखा गया है कि स्वास्थ्य सुरक्षा विश्लेषिकी के क्षेत्र में काफी अनुसंधान हुआ है। प्रसूतिशास्त्र में, गर्भावस्था के प्रतिकूल परिणामों ने दुनिया भर में अधिक से अधिक ध्यान आकर्षित किया है। गर्भावस्था वह समय है जिसके दौरान एक या एक से अधिक संतान गर्भ के अंदर विकसित होती हैं और उस अवधि को गर्भावधि भी कहा जाता है। गर्भावस्था के लक्षण हर महिलाओं के अलग अलग हो सकते हैं लेकिन कुछ सामान्य लक्षण हैं जो हरेक महिलाएं अनुभव कर सकती हैं।

नेशनल इंस्टीट्यूट ऑफ चाइल्ड हेल्थ एंड ह्यूमन डेवलपमेंट (NICHD) के अनुसार सिरदर्द, मतली/उल्टी, सूजे हुए स्तन या निपल्स, हल्का रक्तस्राव, निविदा, थकान, लगातार पेशाब, मिजाज परिवर्तन जैसे गर्भावस्था के लक्षण हैं (1)।

सामान्यतः किसी भी बीमारी में केवल एक व्यक्ति जो उस बीमारी से ग्रसित है वही प्रभावित होता है। परंतु प्रसव एक ऐसी स्थिति है जिसमें दो जिंदगियां प्रभावित होती हैं: एक गर्भवती मां और दूसरा गर्भ में पल रहा बच्चा। जिन महिलाओं का उम्र 20 से 30 साल के बीच होता है उनको गर्भावस्था से संबंधित जटिलताएं कम होने का की उम्मीद होती है परंतु जिनकी उम्र 20 से कम या 30 से ज्यादा होता है उन्हें गंभीर जटिलताओं का सामना करना पड़ सकता है।

पेपर का शेष भाग निम्नानुसार आयोजित किया गया है: खंड (section) 2 में पृष्ठभूमि, खंड (section) 3 में संबन्धित कार्य शामिल है, खंड 4 में प्रस्तावित पद्धति का वर्णन किया गया है। इसके अलावा खंड (section) 5 में भविष्यवाणी के लिए इस्तेमाल किए जाने वाले मशीन लर्निंग एल्गोरिथम प्रस्तुत की गई है और अंत में खंड (section) 6 में प्रस्तुत शोध पत्र का निष्कर्ष दिया गया है।

2. पृष्ठभूमि :

नेशनल इंस्टीट्यूट ऑफ चाइल्ड हेल्थ एंड ह्यूमन डेवलपमेंट (NICHD) के अनुसार (1), गर्भावस्था के दौरान कुछ सामान्य जटिलताओं में शामिल हैं जैसे प्रीक्लेम्पसिया, गर्भपात, उच्च रक्तचाप, गर्भकालीन मधुमेह, संक्रमण, अपरिपक्व श्रम इत्यादि। गर्भावस्था की अवधि के दौरान भ्रूण की वृद्धि की निगरानी करना अत्यंत आवश्यक है। गर्भावस्था के दौरान और बाद में शिशु का आकार और वजन सामान्य होना चाहिए। स्टैनफोर्ड चिल्ड्रेन्स हेल्थ के अनुसार (2), गर्भावस्था में कुछ बच्चे औसत से छोटे होते हैं जिसे Small-for-gestational-age (SGA) कहा जाता है। SGA उन नवजात शिशुओं पर लागू होता

है जिनका जन्म वजन 10 वें प्रतिशत से कम है। ये बच्चे एक ही गर्भकालीन उम्र के कई अन्य शिशुओं की तुलना में छोटे होते हैं।

Small for Gestational Age Advisory Board द्वारा आयोजित सम्मेलन के अनुसार, SGA से प्रभावित शिशुओं के वजन और/ या ऊंचाई समान गर्भावधि उम्र के लिए 3 प्रतिशत से कम है। SGA बच्चों को जन्म के समय, स्कूल के समय और वयस्कता के दौरान विभिन्न चुनौतियों का सामना करना पड़ता है, क्योंकि उनके जन्म के समय उनका वजन कम होता है। इसके अलावा, नवजात श्वसन संकट सिंड्रोम, नवजात हाइपोथर्मिया, नवजात हाइपोग्लाइसीमिया, और समयपूर्वता स्तर III रेटिनोपैथी जैसे रोग विकसित हो सकते हैं। SGA संक्रमित बच्चों के लिए सबसे डरावना तो तब होता है जब उन्हें मौत का सामना करना पड़ता है। बच्चों का छोटा होने का मुख्य कारण उनका विकास में वृद्धि कम होना होता है। उन बच्चों को बराबर मात्रा में ऑक्सीजन या पोषक पदार्थ न मिलने के कारण उनके अंगों और ऊतकों का विकास नहीं हो पाता है। अंतर-गर्भाशय वृद्धि अवरोध (IUGR) के रूप में जाना जाने वाला एक विकार इन शिशुओं में से कई को प्रभावित करता है। माँ में बीमारी, प्लेसेंटा की गंभीर समस्या आदि के कारण, गर्भावस्था और प्रसव के दौरान शिशुओं और माँ दोनों को जीवन के जोखिमों में वृद्धि होती है और उस स्थिति को अंतर-गर्भाशय वृद्धि अवरोध (IUGR) कहा जाता है। यदि सही निगरानी, समय पर डिलीवरी और प्रारंभिक नवजात प्रबंधन किया जाता है, तो SGA की प्रसवकालीन रुग्णता और मृत्यु दर के जोखिम को कम किया जा सकता है।

FGR या IUGR एक ऐसी स्थिति है जिसमें एक अजन्मा बच्चा (भ्रूण) अपेक्षा से छोटा होता है। यूनिवर्सिटी ऑफ रेचेस्टर मेडिकल सेंटर में प्रकाशित हेल्थ एनसाइक्लोपीडिया के अनुसार, FGR का प्रभाव बच्चे की उम्र, साथ ही अंग ऊतक और कोशिका विकास पर भी दिखाई देता है। कभी-कभी ऐसा

होता है कि FGR शिशुओं में कोई प्रभाव दिखाई नहीं देता है। माताओं में FGR का कारण शराब का सेवन, धूम्रपान, कम वजन, अपर्याप्त आहार या वजन बढ़ना होता है। बच्चे में FGR का कारण संक्रमण, जन्म दोष, हृदय दोष और जीन या गुणसूत्रों के साथ समस्या होता है।

3. सम्बंधित कार्य :

गर्भावस्था के दौरान होने वाले जटिलताओं के क्षेत्र में विभिन्न प्रकार के शोध किए गए हैं। गर्भावस्था के दौरान जटिलताओं के पूर्वानुमान के लिए विभिन्न मशीन लर्निंग तकनीकों का उपयोग किया जाता है। 2005 में, कुछ लेखकों (12) ने गर्भावस्था के दौरान small for gestational age (SGA) नामक एक महत्वपूर्ण जटिलताओं पर प्रकाश डाला। भ्रूण की जटिलताओं के बढ़ते जोखिम के कारण, SGA भ्रूण को पहचानने की आवश्यकता है। मातृ कारकों और जैव-भौतिक और जैव रासायनिक मार्करों के आधार पर 11-13 सप्ताह के गर्भ में, प्रीक्लेम्पसिया (PE) की अनुपस्थिति में SGA के पूर्वानुमान के लिए एक मॉडल बनाया गया था (6)। भविष्यवाणी हेतु लिए गए मापदंडों में मुख्य रूप से PAPP-A, मातृ विशेषताएं, NT की मोटाई और β -hCG थे। इन्होंने रिग्रेशन एनालिसिस तकनीक का इस्तेमाल किया था।

2011 में कुछ लेखकों (11) ने प्रीक्लेम्पसिया की अनुपस्थिति में SGA नवजात शिशु के predictors की खोज की। उनके अनुसार जैसा कि George Karagiannis ने 2010 बतलाया था वही प्रिडिक्टर हम इस्तेमाल कर सकते हैं। St. Louis City में गर्भकालीन आयु वर्ग के लिए जन्म और मृत्यु के प्रमाण पत्र से प्राप्त रिकॉर्ड का उपयोग करके SGA से संबंधित सामाजिक, गतिविधि और शारीरिक जोखिम वाले कारकों को समझने के लिए 2014 में एक गहन अध्ययन किया गया था (14)। 2015 में कुछ लेखकों (8) ने एक पेपर प्रकाशित किया था जिसमें SVM, RF, LR और Sparse LR जैसे विभिन्न मशीन लर्निंग तकनीकों के बीच तुलना की गई थी।

2015 में कुछ लेखकों (17) ने SGA नवजात शिशुओं की भविष्यवाणी पर ध्यान केंद्रित किया, जिसमें प्री-एक्लेम्पसिया (PE) की अनुपस्थिति में भ्रूण बायोमेट्रिक्स द्वारा 30 से 34 सप्ताह में स्क्रीनिंग की गई थी। यहां विश्लेषण हेतु पैरामीटर मातृ कारक, पेट परिधि, सिर परिधि का z Score और जांघ की हड्डी की लंबाई या अनुमानित भ्रूण वजन लिए गए थे। भ्रूण की असामान्यता (20) का पता लगाने के लिए विधी रावत द्वारा समान मापदंडों का उपयोग किया गया था। SGA का अनुमान लगाने के लिए मल्टीवीरेबल लॉजिस्टिक रिग्रेशन का इस्तेमाल किया गया था।

2018 में कुछ लेखकों के द्वारा (10) sFlt-1 / PIGF परिमाणात्मक संबंध को जन्म के समय SGA के अनुमान के लिए मापदंडों के रूप में इस्तेमाल किया गया जाने वाला मापदंड बतलाया गया। 2019 में Anca Ciobanu और उनकी टीम ने SGA नवजात शिशुओं के पूर्वानुमान पर ध्यान केंद्रित किया। पारंपरिक दृष्टिकोण की तुलना में तीसरी तिमाही के दौरान सोनोग्राफी भ्रूण की बायोमेट्री द्वारा सटीकता देखी जाती है (1)।

SGA की भविष्यवाणी के लिए विभिन्न कारक जिम्मेदार हैं जिनमें मातृ कारक और विकास वेग महत्वपूर्ण भूमिका निभाते हैं। यदि मूल्यांकन और जन्म के बीच का अंतराल संक्षिप्त है, तो SGA की भविष्यवाणी के लिए सोनोग्राफिक गणना योग्य भार का प्रदर्शन उच्चतम है। 2020 में JING CHENG और उनकी टीम ने SGA और AGA late period

शिशुओं के लिए अव्यक्त जोखिम कारकों के विश्लेषण पर प्रकाश डाला। उनके (9) अनुसार SGA के प्रसवकालीन जोखिम कारक असामान्य गर्भनाल, maternal pregnancy induced hypertension, गर्भकालीन मधुमेह, गर्भावस्था के दौरान संक्रमण और अंतर्गर्भाशयी संकट हैं। 2020 में (15) मातृ विशेषताओं और केस हिस्ट्री से SGA प्रभावित नए जन्मे शिशुओं की भविष्यवाणी पर ध्यान केंद्रित करते हैं। यहाँ प्रसव के समय निषेचन आयु और जन्म-भार Z- स्कोर वर्ग माप को निरंतर चर के रूप में माना जाता है। उनके द्वारा किए गए विश्लेषण कार्य के अनुसार, SGA की भविष्यवाणी में प्रत्येक निषेचन आयु का वितरण और जन्म-भार Z- स्कोर शामिल है। एक मॉडल विकसित किया गया है, जिसके भीतर प्रसव के समय किसी भी विशिष्ट कट-ऑफ जेड-स्कोर और निषेचन आयु के जोखिम को रेखांकित करने के लिए लागू किया जाता है।

अंतर - गर्भाशय वृद्धि अवरोध (IUGR) की भविष्यवाणी करने के लिए बायोमार्कर की समीक्षा 2013 में कुछ लेखकों के द्वारा की गई थी और प्रसूति और स्त्री रोग (3) के लिए एक अंतरराष्ट्रीय पत्रिका में प्रकाशित हुई थी। 2018 में Preterm Infants Survival Assessment (PISA) प्रेडिक्टर पर एक वैज्ञानिक रिपोर्ट (20) प्रकाशित की गई थी। Association for the Advancement of Artificial Intelligence (21) में एक पेपर प्रकाशित किया गया था जिसमें रैंडम फारेस्ट, XGBoost, और लाइट जीबीएम एल्गोरिथ्म शामिल थे, इसमें गर्भावधि उम्र के साथ भ्रूण के वजन की भविष्यवाणी की गई थी।

टेबल 1: सारांश

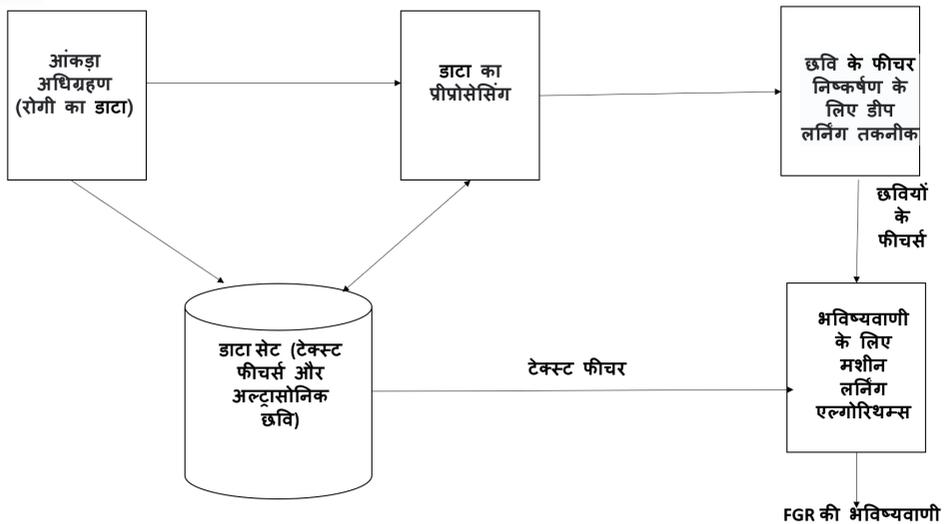
क्रमांक	पेपर का शीर्षक	वर्ष	सार
1.	Abnormal fetal growth: intrauterine growth retardation, small for gestational age, large for gestational age	2004	भ्रूण के विकास के लिए जिम्मेदार कारक मातृ आकार और पोषण, मातृ रोग, बाहरी कारक, अपरा कारक, भ्रूण कारक, बाल स्वास्थ्य संबंधी विचार, नवजात जटिलताएं हैं।

2.	Ultrasound Estimation of Fetal Weight by Artificial Neural network Using crown coccyx length	2010	भ्रूण के वजन के अनुमान में सुधार के लिए Computerized artificial neural network विकसित किया गया। Biparietal diameter (BPD), occipitofrontal diameter (OFD), abdominal circumference (AC), femur length (FL) और crown coccyx length (CCL) को भ्रूण के वजन का अनुमान लगाने के लिए एक पैरामीटर के रूप में इस्तेमाल किया जा सकता है।
3.	Novel biomarkers for predicting intrauterine growth restriction: a systematic review and meta-analysis	2013	IUGR की भविष्यवाणी के लिए बायोमार्कर के रूप में बायोफिजिकल पैरामीटर और मातृ विशेषताएं इस्तेमाल किया जा सकता है।
4.	Machine Learning for Fetal Growth Prediction	2018	भ्रूण के वजन की भविष्यवाणी सपदमंत और quantile regression, random forests, Bayesian additive regression trees, और generalized boosted models का उपयोग करके की जा सकती है।
5.	Feature Extraction using Convolution Neural Networks (CNN) and Deep Learning	2018	KNN, SVM, SOFTMAX, Fully Connected NN और CNN जैसे विभिन्न वर्गीकरण एल्गोरिदम का उपयोग किया गया है जिसमें छवि वर्गीकरण के लिए CNN 85.97% सटीकता देता है।
6.	Machine-learning-based automatic identification of fetal abdominal circumference from ultrasound images	2018	CNN और U-Net का उपयोग 2 D अल्ट्रासाउंड डेटा से स्वचालित भ्रूण बायोमेट्री अनुमान के लिए विधि के रूप में किया जा सकता है।
7-	Ensemble Machine Learning for Estimating Fetal Weight at Varying Gestational Age	2019	प्रस्तावित म्दमउइसम मॉडल अन्य एकल मशीन लर्निंग मॉडल की तुलना में भ्रूण के जन्म के वजन की भविष्यवाणी बेहतर करता है। Random Forest, XGBoost, और LightGBM एल्गोरिदम से युक्त Ensemble मॉडल का उपयोग किया जाता है।
8.	Deep learning for heterogeneous medical data analysis	2019	डीप लर्निंग टेक्नोलॉजी पूरी तरह से अन्य तकनीक को प्रतिस्थापित नहीं कर सकती है, लेकिन नए मॉडल को स्थापित करने के लिए डीप लर्निंग और पारंपरिक मॉडल के संयोजन की खोज करने की आवश्यकता है।

9.	Achieving accurate estimates of fetal gestational age and personalized predictions of fetal growth based on data from an international perspective cohort study: a population-based machine learning study	2020	अल्ट्रासाउंड-व्युत्पन्न और भ्रूण बायोमेट्रिक डेटा का उपयोग करके गर्भकालीन आयु का सटीक अनुमान लगाने के लिए मशीन लर्निंग विकसित किया गया है।
----	--	------	--

4. प्रस्तावित पद्धति :

हमारे प्रस्तावित कार्य बच्चों में मृत्यु दर और रुग्णता के प्रमुख कारणों के लिए मॉडल के विकास पर आधारित होंगे। गर्भावस्था के दौरान कम वजन वाला बच्चा ज्वलंत जटिलताओं में से एक है। हमारा शोध भारतीय महिला के लिए भ्रूण वृद्धि प्रतिशोध (FGR) की भविष्यवाणी पर आधारित है। चित्र: 1 हमारे प्रस्तावित कार्य के प्रणाली कार्य प्रवाह को दर्शाता है।



चित्र 1: प्रणाली कार्य प्रवाह

प्रणाली कार्य प्रवाह को चार भागों में वर्गीकृत किया गया है।

क. आंकड़ा अधिग्रहण:

आंकड़ा अधिग्रहण के लिए, अस्पताल में स्थापित ऐप का उपयोग करके डेटा एकत्र किया जा सकता है। ऐप के द्वारा टेक्स्ट फीचर्स और अल्ट्रासोनोग्राफिक चित्र को एकत्रित किया जा सकता है। जिस ऐप के माध्यम से हम इमेज और टेक्स्ट फीचर एकत्र करेंगे, वह चित्र 2 में दिखाया गया है।

कौलेश्वर प्रसाद, एम.बी. पद्मावती एवं पवन कुमार पटनायक, “डीप लर्निंग तकनीक का उपयोग करते हुए भ्रूण वृद्धि.....”

चित्र 2 : ऐप के द्वारा आंकड़ा अधिग्रहण

1. टेक्स्ट फीचर्स: टेक्स्ट फीचर्स में मूल रूप से रोगी की सामान्य जानकारी, रोगी के बच्चों की जानकारी, रिश्तेदारों की जानकारी (रोगी के पिता पक्ष), रक्त शामिल होंगे। रोगी की सामान्य जानकारी में नाम, जन्म तिथि, लिंग, मोबाइल नंबर, पता, रक्त समूह, विवाहित / अविवाहित, बच्चों की संख्या, धूम्रपान करने की आदतें, मधुमेह, गर्भावस्था के पूर्व वजन, ऊंचाई, वंश, सामाजिक आर्थिक स्थिति, गर्भावस्था में वजन बढ़ना, पति की धूम्रपान की स्थिति और पति का वजन और ऊंचाई शामिल हैं। रोगी के बच्चों की जानकारी में किसी भी चिकित्सा जटिलताओं, गर्भावस्था के दौरान जटिलताओं और प्रसव और गर्भपात की जानकारी के दौरान जटिलताएं शामिल हैं। रक्त जांच फीचर्स में हीमोग्लोबिन होता है।

2. छवि फीचर्स: इसे अल्ट्रासोनोग्राफी से एकत्र किया जा सकता है। एकत्र की गई फीचर्स डॉपलर, बायोफिजिकल प्रोफाइल (BPP), शराब, अनुमानित वजन, फंडल ऊंचाई, पेट की परिधि, नैदानिक वजन अनुमान और भ्रूण चाल हो सकते हैं।

ख. डाटा प्रीप्रोसेसिंग:

एप्लिकेशन के माध्यम से डाटा एकत्र किए जाने के बाद डाटा को प्रीप्रोसेस करना आवश्यक है। इसके लिए निम्नलिखित बिंदु उपयोगी हैं।

- पहले से मौजूद डाटा की संशोधित प्रतियों को जोड़कर डाटा की मात्रा बढ़ाई जा सकती है। इस विधि को डाटा वृद्धि कहा जाता है।
- शून्य मानों को संभालने के लिए विभिन्न समाधानों को अपनाया जा सकता है। उसके लिए शून्य मानों की जगह पर खाली जगह, माध्य या संबंधित कॉलम में मोड के साथ बदल दिया जाता है या फिर डाटा महत्वपूर्ण नहीं है तो रिकॉर्ड को हटा दिया जाता है।
- डेटासेट के गुम मानों को कुछ मानों के साथ प्रतिस्थापित किया जाता है। प्रक्रिया को इंप्यूटेशन कहा जाता है।
- मानकीकरण की प्रक्रिया को अपनाया जा सकता है।
- ऑर्डिनल और नाममात्र श्रेणीबद्ध चर को प्रीप्रोसेस करने की आवश्यकता है।

ग. छवि की फीचर्स निष्कर्षण के लिए कॉन्वोलुशन न्यूरल नेटवर्क (CNN):

CNN डीप न्यूरल नेटवर्क का एक वर्ग है जिसमें इसका उपयोग दृश्य कल्पना के विश्लेषण के लिए किया जाता है। रेगुलर न्यूरल नेटवर्क और CNN के बीच अंतर यह है कि CNN की परतें 3 आयामों की ऊंचाई, गहराई और चौड़ाई है। CNN में परतों के बीच ऐसा कोई निर्भरता नहीं है जैसा कि रेगुलर

न्यूरल नेटवर्क में होता है। CNN में 2 प्रमुख भाग होते हैं:

फीचर्स निकासी:

यहाँ फीचर्स को निकालने के लिए कॉन्वोलुशन और पूलिंग संचालन का क्रम किया जाता है। हमारे काम में, निकाली गई छवि फीचर्स के रूप में डॉपलर, बायोफिजिकल प्रोफाइल, liquor और अनुमानित वजन हैं।

- 1) कॉन्वोलुशन: कॉन्वोलुशन ऑपरेशन का उपयोग करके फीचर एक्सट्रैक्शन में एक कर्नेल / फिल्टर वाली इनपुट इमेज ली जाती है। स्क्रीन की चौड़ाई को कवर करने के बाद ऊपर से थोड़ा नीचे और बाएं से दाएं जाने वाली स्क्रीन को स्कैन किया जाता है। कुल स्क्रीन स्कैन होने तक यह विधि पुनरावृत्ति होती है। उदाहरण के लिए, इनपुट छवि और फिल्टर निम्नानुसार दिखाई देते हैं:

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

चित्र 2 (अ): इनपुट इमेज

1	0	1
0	1	0
1	0	1

चित्र 2 (ब): कर्नेल / फिल्टर

इस पर खिसकने पर, फिल्टर अपने स्वयं के मानों को छवि के अत्यधिक मानों के साथ गुणा करता है और उन सभी को जोड़ती है और प्रत्येक ओवरलैप के साथ एक मूल्य को आउटपुट करता है। संपूर्ण

ई कार्य का एक उदाहरण चित्र में दिखाया गया है।

4	3	4
2	4	3
2	3	4

चित्र 2 (स): आउटपुट मैट्रिक्स

आउटपुट को रेक्टिफाइड लीनियर फंक्शन के इनपुट के रूप में दिया जाता है जो नकारात्मक को शून्य और सकारात्मक मानों में परिवर्तित करता है।

- 2) पूलिंग: पूलिंग लेयर, निकाले गए फीचर के स्थानिक आकार को कम करता है। दो प्रकार की पूलिंग उपलब्ध हैं: मैक्स पूलिंग और औसत पूलिंग।

घ. वर्गीकरण:

यहां, इन निकाले गए फीचर के ऊपर से, पूरी तरह से जुड़ी हुई परतें एक क्लासिफायर के रूप में कार्य करेंगी। वे इस बात की संभावना को बताएंगे कि एल्गोरिथम छवि पर ऑब्जेक्ट के लिए इसकी भविष्यवाणी करता है।

5. भविष्यवाणी के लिए मशीन लर्निंग एल्गोरिथम:

डिसीजन ट्री (Decision Tree), लॉजिस्टिक रिग्रेशन (Logistic Regression), रैंडम फॉरेस्ट (Random Forest), सपोर्ट वेक्टर मशीन (Support Vector Machine) जैसे कई मशीन लर्निंग एल्गोरिथम हैं जो भ्रूण के विकास मंदता की भविष्यवाणी करने के लिए उपलब्ध हैं। डिसीजन ट्री डेटा माइनिंग की एक विधि है जिसका उपयोग कई कोवैरिएट के आधार पर वर्गीकरण के लिए किया जाता है। इसका उपयोग लक्ष्य चर भविष्यवाणी एल्गोरिथम के विकास के लिए किया जाता है। सपोर्ट वेक्टर मशीन वर्गीकरण और प्रतिगमन के अध्ययन के लिए उपयोग की जाने

वाली पर्यवेक्षण सीखने के लिए एक दृष्टिकोण है। SVM का उद्देश्य N - dimensional space (N = फीचर्स की संख्या) में अत्यधिक मार्जिन वाले hyper plane का निरीक्षण करना है जो डेटा बिंदुओं को वर्गीकृत करता है। रैंडम फॉरेस्ट या रैंडम डिस्ीजन फॉरेस्ट एक एंसंबल क्लासिफायर है जो डिस्ीजन ट्री एल्गोरिथम को बेतरतीब ढंग से इस्तेमाल करता है। लॉजिस्टिक रिग्रेशन (LR) कुछ घटना या वर्ग के संभावित मॉडल पर आधारित है, जैसे कि विफल / पास, हार / जीत, बीमार / स्वस्थ या मृत / जीवित।

6. निष्कर्ष:

भ्रूण के विकास मंदता के पूर्वानुमान के रूप में विभिन्न कारकों जैसे मातृ कारक, बायोफिजिकल और जैविक मार्कर को लिया जाता है। ये पैरामीटर टेक्स्ट और छवियों के रूप में हो सकते हैं। डीप लर्निंग तकनीक जैसे कन्वॉल्यूशन न्यूरल नेटवर्क का उपयोग किया जाता है जिसमें छवि वर्गीकरण में बड़े अनुप्रयोग होते हैं। FGR की भविष्यवाणी के लिए मशीन लर्निंग का भी उपयोग किया जा सकता है।

इस समीक्षा पत्र से प्रस्तावित किया जाता है कि FGR की भविष्यवाणी के लिए टेक्स्ट और इमेज फीचर्स का इस्तेमाल किया जा सकता है जिसमें कन्वॉल्यूशन न्यूरल नेटवर्क (CNN) का इस्तेमाल कर अल्ट्रासोनोग्राफी से इमेज फीचर्स उद्धरण किया जा सकता है। इसके पश्चात टेक्स्ट फीचर्स और इमेज फीचर्स को मिलाकर एक नया फीचर तैयार कर भ्रूण वृद्धि प्रतिशोध की भविष्यवाणी के लिए बहुत सारे मशीन लर्निंग एल्गोरिथम (Machine Learning Algorithm) जैसे डिस्ीजन ट्री (Decision Tree), लॉजिस्टिक रिग्रेशन (Logistic Regression), रैंडम फॉरेस्ट (Random Forest), सपोर्ट वेक्टर मशीन (Support Vector Machine) का इस्तेमाल किया जा सकता है।

7. प्रमुख शब्दों की तालिका :

Technical Terms (English)	तकनीकी शब्द (हिंदी)
Classification	वर्गीकरण
Convolution Neural Network	कन्वॉल्यूशन न्यूरल नेटवर्क
Data Acquisition	आंकड़ा अधिग्रहण
Fetal Growth Retardation	भ्रूण के विकास मंदता
Logistic Regression	लॉजिस्टिक रिग्रेशन
Machine Learning Algorithm	मशीन लर्निंग एल्गोरिथ्म
Random Forest	रैंडम फॉरेस्ट
Support Vector Machine	सपोर्ट वेक्टर मशीन

संदर्भ:

- [1] A. CIOBANU, C. F. (2019). Prediction of small-for-gestational-age neonates at 35–37 weeks’ gestation: contribution of maternal factors and growth velocity between 20 and 36 weeks. *Ultrasound Obstet Gynecol*, 488-495.
- [2] Anca Ciobanu, M., Angeliki Rouvali, M., Argyro Syngelaki, P., Ranjit Akolekar, M., & Kypros H. Nicolaides, M. (2019). Prediction of small for gestational age neonates: screening by maternal factors, fetal biometry, and biomarkers at 35-37 weeks’ gestation. *American Journal of Obstetrics*, 1-11.
- [3] A Conde-Agudelo, A. P. (2013). Novel biomarkers for predicting intrauterine growth restriction: a systematic review and meta-analysis. *International Journal of Obstetrics and Gynaecology*, 681-694.
- [4] Ashley I. Naimi, R. W. (2018). *Machine Learning for Fetal Growth Prediction*. Wolters Kluwer Health, Inc., 1-28.
- [5] Bukweon Kim, K. C.-Y. (2018). Machine-learning-based automatic identification of fetal abdominal circumference from ultrasound images. *IPEM*, 1-22.
- [6] George Karagiannis, R. A. (2010). Prediction of Small-for-Gestation Neonates from Biophysical and Biochemical Markers at 11–13 Weeks. *Karger*, 1-7.
- [7] Hanieh Mohammadi, M. J. (2010). Ultrasound Estimation of Fetal Weight by Artificial Neural network Using crown coccyx length. *International Conference on Measurement and Control Engineering (ICMCE)*, (pp. 518-522).
- [8] Jianqiang Li, L. L.-J. (2015). Comparison of Different Machine Learning Approaches to Predict Small for Gestational Age Infants. *IEEE TRANSACTIONS ON BIG DATA*, 1-14.
- [9] JING CHENG, J. L. (2020). Analysis of perinatal risk factors for small for gestational age and appropriate for gestational age late term infants. *EXPERIMENTAL AND THERAPEUTIC MEDICINE*, 1719-1724.
- [10] Lena Heidi Bækgaard Thorsen, L. B. (2018). Prediction of birth weight small for gestational age with and without preeclampsia by angiogenic markers: An Odense Child Cohort study. *The Journal of Maternal-Fetal & Neonatal Medicine*.
- [11] Leona C. Y. Poon, G. K. (2011). Reference range of birth weight with gestation and first-trimester prediction of small-for-gestation neonates. *Prenat Diagn*, 58–65.
- [12] Lin Yue, D. T. (2019). *Deep learning for heterogeneous medical data analysis*. Springer, 1-23.
- [13] MOLIN, P. G. (2005). Does antenatal identification of small-for-gestational age fetuses significantly improve their outcome? *Ultrasound Obstet Gynecol*, 258-264.
- [14] Pamela K. Xaverius, J. S. (2014). Predictors of Size for Gestational Age in St. Louis City and County. *Hindawi*, 1-8.

- [15] PAPASTEFANOU, D. W. (2020). Competing-risks model for prediction of small-for-gestational age neonate from maternal characteristics and medical history. *Ultrasound Obstet Gynecol*, 196-205.
- [16] Russell Fung, J. V.-U. (2020). Achieving accurate estimates of fetal gestational age and personalised predictions of fetal growth based on data from an international prospective cohort study: a population based machine learning study. *Lancet*, 368-375.
- [17] S. BAKALIS, M. S. (2015). Prediction of small-for-gestational-age neonates: screening by fetal biometry at 30–34 weeks. *Ultrasound Obstet Gynecol*, 551-558.
- [18] Stefan Kuhle, B. M. (2018). Comparison of logistic regression with machine learning methods for the prediction of fetal growth abnormalities: a retrospective cohort study. *BMC Pregnancy and Childbirth*, 1-9.
- [19] Utpala (“Shonu”) G. Das, a. G. (2004). Abnormal fetal growth: intrauterine growth retardation, small for gestational age, large for gestational age. Elsevier, 639-654.
- [20] Vidhi Rawat, A. J. (2018). Automated Techniques for the Interpretation of Fetal Abnormalities: A Review. *Hindawi Applied Bionics and Biomechanics*, 1-12.
- [21] Yu Lu, X. Z. (2019). Ensemble Machine Learning for Estimating Fetal Weight at Varying Gestational Age. *The Thirty-First AAAI Conference on Innovative Applications of Artificial Intelligence (IAAI-19)*, (pp. 9522-927).

**भारतीय परमाणु कार्यक्रम के जनक डॉ होमी जहांगीर भाभा
(30 अक्टूबर, 1909 – 24 जनवरी, 1966)**

भारतीय परमाणु कार्यक्रमों को विश्व के उन्नत और सफल परमाणु कार्यक्रमों में शुमार करने और परमाणु शक्ति-संपन्न राष्ट्रों की अग्रिम पंक्ति में खड़ा करने का श्रेय जाता है भारतीय परमाणु कार्यक्रम के जनक डॉ होमी जहांगीर भाभा को। डॉ होमी जहांगीर भाभा यानी परमाणु भौतिकी विज्ञान का ऐसा चमकता सितारा, जिसका नाम सुनते ही हर भारतवासी का सीना गर्व से चौड़ा हो जाता है। डॉ होमी जहांगीर भाभा ही वह शख्स थे, जिन्होंने भारत के परमाणु ऊर्जा कार्यक्रम की कल्पना की, और भारत को परमाणु शक्ति सम्पन्न तथा वैज्ञानिक अनुसंधान के क्षेत्र में अग्रसर होने का मार्ग प्रशस्त किया। मुट्ठी भर वैज्ञानिकों की सहायता से परमाणु क्षेत्र में अनुसंधान का कार्य शुरू करने वाले डॉ भाभा ने समय से पहले ही परमाणु ऊर्जा की क्षमता और अलग-अलग क्षेत्रों में उसके उपयोग की संभावनाओं की परिकल्पना कर ली थी। यही वजह है कि उन्हें “भारतीय परमाणु ऊर्जा कार्यक्रम का जनक” कहा जाता है।

होमी भाभा की प्रारंभिक शिक्षा मुंबई में हुई। साल 1927 में होमी भाभा आगे की पढ़ाई के लिए इंग्लैंड चले गए और वहां उन्होंने केंब्रिज विश्वविद्यालय से मैकेनिकल इंजीनियरिंग की परीक्षा पास की। साल 1934 में केंब्रिज विश्वविद्यालय से उन्होंने डॉक्टरेट की उपाधि हासिल की। भाभा ने जर्मनी में कॉस्मिक किरणों का अध्ययन किया और उन पर अनेक प्रयोग भी किए। वर्ष 1933 में भाभा ने अपना रिसर्च पेपर “द अब्सॉर्वेशन ऑफ कॉस्मिक रेडिएशन” शीर्षक से जमा किया। इसमें उन्होंने कॉस्मिक किरणों की अवशोषक और इलेक्ट्रॉन उत्पन्न करने की क्षमताओं को प्रदर्शित किया। इस शोध पत्र के लिए उन्हें साल 1934 में ‘आइजैक न्यूटन स्टूडेंटशिप’ भी मिली। डॉ भाभा अपनी शिक्षा पूरी करने के बाद साल 1939 में भारत लौट आए। भारत आने के बाद वह बेंगलुरु के इंडियन इंस्टीट्यूट ऑफ साइंस से जुड़ गए, और साल 1940 में रीडर के पद पर नियुक्त हुए। इंडियन इंस्टीट्यूट ऑफ साइंस में उन्होंने कॉस्मिक किरणों की खोज के लिए एक अलग विभाग की स्थापना की। कॉस्मिक किरणों पर उनकी खोज के चलते उन्हें विशेष ख्याति मिली, और उन्हें साल 1941 में रॉयल सोसाइटी का सदस्य चुन लिया गया।

(शेष पृष्ठ 55 पर)