

УДК: 004.855.5

Эшаров Элзарбек Асанович
ф.-м.и.к., доцент, Ош мамлекеттик университети
esharov@oshsu.kg

Эшаров Элзарбек Асанович
к.ф.-м.н., доцент, Ошский государственный университет
esharov@oshsu.kg

Esharov Elzarbek Asanovich
Candidate of Sciences in Physico-Mathematical Sciences, Associate Professor,
Osh State University
esharov@oshsu.kg

Асилбеков Тынчтыкбек Майрамбекович
окутуучу, Ош мамлекеттик университети
mir.titan.90@gmail.com

Асилбеков Тынчтыкбек Майрамбекович
преподаватель, Ошский государственный университет
mir.titan.90@gmail.com

Asilbekov Tynchtykbek Mairambekovich
Lecturer, Osh State University
mir.titan.90@gmail.com

**ВЕЙВЛЕТ ӨЗГӨРТҮҮЛӨРҮНӨ НЕГИЗДЕЛГЕН АЙЫЛ ЧАРБАСЫНДА ӨСҮМДҮК
ООРУЛАРЫН ПРОГНОЗДОО ҮЧҮН ТЕРЕҢ
ОКУТУУ МОДЕЛДЕРИН ИШТЕП ЧЫГУУ**

**РАЗРАБОТКА МОДЕЛЕЙ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ БОЛЕЗНЕЙ
РАСТЕНИЙ В СЕЛЬСКОМ
ХОЗЯЙСТВЕ НА ОСНОВЕ ВЕЙВЛЕТ ПРЕОБРАЗОВАНИЙ**

*DEVELOPMENT OF DEEP LEARNING MODELS FOR PREDICTING PLANT DISEASES IN
AGRICULTURE BASED ON WAVELET
TRANSFORMATIONS*

ВЕЙВЛЕТ ӨЗГӨРТҮҮЛӨРҮНӨ НЕГИЗДЕЛГЕН АЙЫЛ ЧАРБАСЫНДА ӨСҮМДҮК ООРУЛАРЫН ПРОГНОЗДОО ҮЧҮН ТЕРЕҢ ОКУТУУ МОДЕЛДЕРИН ИШТЕП ЧЫГУУ

Аннотация

Бул макалада вейвлет өзгөртүүлөрүн жана терең окутуу ыкмаларын колдонуу менен өсүмдүк ооруларын классификациялоо үчүн моделдер (PlantVillage) каралган. Өсүмдүктөрдү классификациялоо үчүн вейвлет трансформациялары бар конволюциялык нейрон тармагынын (Convolutional Neural Network (CNN) – Сверточная нейронная сеть) моделдери тургузулган. Өсүмдүктөрдү натыйжалуу коргоо үчүн абдан маанилүү болгон өсүмдүк жалбырактарынын ооруларын классификациялоо үчүн моделдер тургузулган. Натыйжалуу ыкмалар жана конволюциялык нейрон тармактары (CNN) тургузулган. Бул иштин негизги жетишкендиги - терең окутуу ыкмаларын WaveletFusion өзгөртүүлөрү менен интеграциялоо. Терең окутуу алкагында моделдөөнүн жаңы ыкмасы моделдердин тактыгын жогорулатуу үчүн ар кандай атайын активдештирүү функцияларын колдонулат. Сунушталган технология нейрондук моделдөөнүн которуу менен окутуусуна негизделген кодоочу-декодоочу архитектурада стационардык вейвлет өзгөртүүлөрүнүн (Stationary Wavelet Transform (SWT) – Стационарное вейвлет-преобразование), дискреттик вейвлет өзгөртүүлөрүнүн (Discrete Wavelet Transform (DWT) – дискретное вейвлет-преобразование) жана боз түстөгү сүрөттөрдүн канал боюнча конкатенациясын бириктирет.

Ачкыч сөздөр: вейвлет өзгөртүүлөр, терең окутуу, конволюциялык нейрон тармактары, моделдөө, прогноздоо, моделдин тактыгы жана каталары, өсүмдүк оорулары

Разработка моделей глубокого обучения для прогнозирования болезней растений в сельском хозяйстве на основе вейвлет преобразований

Development of deep learning models for predicting plant diseases in agriculture based on wavelet transformations

Аннотация

С применением вейвлет-преобразований и методов глубокого обучения построены модели для классификации болезней растений (PlantVillage). Построены CNN (Convolutional Neural Network – Сверточная нейронная сеть) модели с вейвлет-преобразованиями для классификации растений. Построены модели классификации болезней листьев растений, которые имеют решающее значение для эффективной защиты урожая. Построены эффективные методы и построены сверточные нейронные сети CNN. Основным достижением работы является интеграция методов глубокого обучения с WaveletFusion преобразованиями. Новый подход в моделировании в структуре глубокого обучения использует различные виды специальных функций активации для улучшения точности моделей. Предлагаемая технология интегрирует по каналную конкатенацию стационарного вейвлет-преобразования (Stationary Wavelet Transform (SWT) – Стационарное вейвлет-преобразование (СВП)), дискретного вейвлет-преобразования (Discrete Wavelet Transform (DWT) – дискретное вейвлет-преобразование (ДВП)) и изображений в оттенках серого в архитектуре кодировщика-декодера на основе трансферного обучения нейронного моделирования.

Ключевые слова: вейвлет преобразования, глубокое обучения, сверточные нейронные сети, моделирование, прогнозирование, точность и ошибки моделей, болезни растений

Abstract

Using wavelet transformations and deep learning methods, models for the classification of plant diseases (PlantVillage) have been built. CNN models with wavelet transformations for plant classification are constructed. Models of classification of diseases of plant leaves, which are crucial for effective crop protection, are constructed. Effective methods have been developed and CNN convolutional neural networks have been built. The main achievement of the work is the integration of deep learning methods with WaveletFusion transformations. A new approach to deep learning modeling uses various types of special activation functions to improve model accuracy. The proposed technology integrates channel-by-channel concatenation of stationary wavelet transform (SWT), discrete wavelet transform (DWT) and grayscale images in the encoder-decoder architecture based on transfer learning of neural modeling.

Keywords: wavelet transformations, deep learning, convolutional neural networks, modeling, forecasting, model accuracy and errors, plant diseases

Киришүү

Вейвлет өзгөртүүлөр – сигналдарды талдоо үчүн күчтүү математикалык курал болуп саналат, ал убакыт жана жыштык чөйрөлөрүндөгү сигналдарды изилдөөгө мүмкүндүк берет. Жыштык маалыматын гана берген Фурье өзгөртүүлөрүнөн айырмаланып, вейвлет өзгөртүүлөр сигналдын жергиликтүү убакыт-жыштык көрсөтүлүшүн камсыз кылат. Мындай көйгөйлөрдү чечүү үчүн биз стационардык вейвлет өзгөртүүлөр (CBӨ – Stationary Wavelet Transform – SWT) (V. Tomar, et al., p.12.; T. Jackson, p.1-4, M.R.O. Onwunali, R.B. Mabagala, pp. 37-44), дискреттик вейвлет өзгөртүүлөр (ДБӨ – Discrete Wavelet Transform – DWT) жана ResNet негизиндеги классификатор менен өркүндөтүлгөн коддогуч-декоддоочу архитектурадагы боз түстүү сүрөттү айкалыштырган жаңы ыкманы сунуштайбыз. Вейвлет өзгөртүүлөр көп масштабдуу анализди жүргүзүүгө мүмкүндүк берет, бул өсүмдүктөрдүн ооруларынын так классификациялоо үчүн маанилүү болгон жалбырак сүрөттөрүнүн глобалдык структураларын (мисалы, жалбырактын формасы, тамыр үлгүлөрү) жана жергиликтүү деталдарын (мисалы, текстура, тактар, жабыркоолор) чагылдырууга мүмкүндүк берет. CBӨ (SWT) жана ДБӨ (DWT) интеграциясы (T. Rouf Shah, pp. 1-9; J. Downer, pp.1-3; S.J. Pethybridge, pp.1-7) иштеринде негизинен маалыматтар топтомун көбөйтүү ыкмасы катары иштеген ар кандай чечилиштерде деталдуу жыштык маалыматын пайдалануу менен өзгөчөлүктөрдү бөлүп алууну жакшыртат (F.S. Ishengoma, ; D. Riehle,). Сунушталган нейрон тармак архитектурасы терең окутуу моделдеринин тактыгын бир топ жакшыртат. Бул көп масштабдуу, интеграцияланган вейвлет ыкмасы моделдин өсүмдүктүн жалбырак ооруларын так жана ишенимдүү аныктоо жөндөмүн бир топ жакшыртат.

Изилдөө ыкмалары жана методологиялары.

Бул изилдөөдө ар кандай айыл чарба өсүмдүктөрүнүн ооруларын таануу маселесин изилдөө үчүн терең окутуу жана сызыктуу эмес моделдерди түзүүнүн күчтүү куралы болгон вейвлет өзгөртүүлөрү колдонулат. Жыштык маалыматын гана берген Фурье өзгөртүүсүнөн айырмаланып, вейвлет өзгөртүүсү терең окутуу ыкмалары менен айкалышып, көптөгөн моделдер үчүн жогорку тактыкты камсыз кылат. Изилдөөдө жүргүзүлгөн бардык эсептөөлөр төмөнкү математикалык аныктамалар жана өзгөртүүлөргө негизделген. Бул изилдөөдө $f(t)$ функциясынын үзгүлтүксүз вейвлет өзгөртүүсү колдонулган жана ал төмөнкүдөй формула менен аныкталган:

$$WW(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (1)$$

где:

$\psi(t)$ – энелик вейвлет (базалык функция),

a – масштабдоо параметри ($a > 0$),

b – жылдыруу параметри,

ψ^* – комплекстүү-жупташкан функция.

Моделдерди куруу үчүн вейвлеттин кабыл алуу шарты жана тескери өзгөртүүнүн болушу $\psi(t)$ вейвети төмөнкү форманын кабыл алуу шартын канааттандырышы керек:

$$C_{\psi\psi} = \int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega < \infty, \quad (2)$$

Кээ бир эсептөөлөрдө тез вейвлет өзгөртүүсү (ТВӨ – Fast Wavelet Transform (FWT) – Быстрое вейвлет-преобразование) колдонулат. Натыйжалуу эсептөө үчүн тез вейвлет өзгөртүүсү (ТВӨ) итеративдик сигналдарды чыпкалоого негизделген Малла алгоритми колдонулат. Дискреттик катарлар тибиндеги ажыратуу колдонулат.

$$c_{jj+1}[k] = \sum_n \psi[n-2k]c_{jj}[n], \quad d_{jj+1}[k] = \sum_n \psi[n-2k]c_{jj}[n], \quad (33)$$

мында $h[n]$ – төмөнкү жыштыктагы чыпка, ал эми $g[n]$ – жогорку жыштыктагы чыпка.

Анын бир аз өзгөртүлүшү, башкача айтканда, реконструкциясы, эсептөөлөр үчүн жакшырткан колдонулуштагы формага ээ болот.

$$c_{jj}[n] = \sum_k h[n-2k]c_{jj+1}[k] + \sum_k g[n-2k]d_{jj+1}[k] \quad (4)$$

Вейвлеттин мисалдары:

Хааранын вейвлетти:

$$\psi(t) = \begin{cases} 1, & 0 \leq t < 0.5, \\ -1, & 0.5 \leq t < 1, \\ 0, & \text{болбосо.} \end{cases} \quad (5)$$


Добеши вейвлетти:

- Компакттуу таянычтуу ортогоналдык вейвлеттердин үй-бүлөсү.


Жыйынтыктарды талкуулоо.

Бул иште колдонулган бардык нейрондук тармак эсептөөлөрү (1) - (5) математикалык формулаларга негизделген. Бул иштин негизги максаты Plant Village чоң маалыматтарына негизделген нейрондук тармактарды тургузуу жана аларды вейвлет технологияларын колдонуу менен өркүндөтүү болгон. PlantVillage тиркемеси – бул интернет байланышы жок эле талаада дыйкандарга өсүмдүк ооруларын аныктоого жардам берүү үчүн санариптик жардамчыны колдонгон коомчулук тарабынан колдоого алынган жана иштелип чыккан тиркеме. Бул ыкма учурда көптөгөн колдонмо маселелерде абдан популярдуу.

Конволюциялык нейрондук тармактар жана вейвлет өзгөртүүлөрү ишке ашыруунун жыйынтыктарын бириктирип жана ошондой эле узакка колдонуу үчүн моделдерди түзөт. CNN нейрондук моделдерине негизделген моделдердин жана вейвлет өзгөртүүлөрүн колдонуу менен курулган CNN моделдеринин тактыгы жана катасы талданат. Жыйынтыктары төмөндө келтирилген.





1-сүрөт. Конволюциялык нейрон тармактарына (CNN) жана вейвлет өзгөртүүлөрүнө (Хаар) негизделген тактык жыйынтыктары



2-сүрөт. CNN конволюциялык нейрон тармактарына жана вейвлет өзгөртүүлөрүнө (Хаар) негизделген моделдердин каталары

Картошка ооруларын классификациялоо үчүн матрица каталыгы көрсөтүлгөн. Бул матрица моделдин класстар боюнча маалыматтарды канчалык так алдын ала айтканын көрсөтөт.



4-сүрөт. Картошка ооруларын классификациялоо үчүн вейвлет өзгөртүүлөрүн колдонуу менен моделдин матрицасынын катачылыгы


1- листинг. Өсүмдүк ооруларынын болжолдоолорунун натыйжалары жеке өсүмдүк (картошка) үчүн CNN прогноздоо негизинде

Base CNN Classification Report (PlantVillage):				
	precision	recall	f1-score	support
Potato_healthy	1.00	0.77	0.87	71
Potato_Late_blight	0.72	0.99	0.83	74
Potato_Early_blight	0.99	0.84	0.91	80
accuracy			0.87	225
macro avg	0.90	0.87	0.87	225
weighted avg	0.90	0.87	0.87	225

2-листинг. Конволюциялык нейрон тармактарын жана вейвлет өзгөртүүлөрүн колдонуу менен картошка оорусунун үч класстык классификациясы үчүн алдын ала айтуу боюнча отчету.

Wavelet CNN Classification Report (PlantVillage):				
	precision	recall	f1-score	support
Potato_healthy	1.00	0.27	0.42	71
Potato_Late_blight	0.51	0.73	0.60	74
Potato_Early_blight	0.79	0.99	0.88	80
accuracy			0.68	225
macro avg	0.77	0.66	0.63	225
weighted avg	0.76	0.68	0.64	225

Төмөндө вейвлет өзгөртүүлөрүн колдонгон моделдерге негизделген өсүмдүк ооруларынын божомолунун салыштырмалуу анализи келтирилген. Моделдердин колдонулушу боюнча маанилүү натыйжа, ошондой эле курулган моделдердин 100% тактыкка канчалык жакын экенин көрсөткөн Area Under Curve (AUC) жана Receiver Operating Characteristic (ROC) ийри сызыктары келтирилген. 3-сүрөттө картошка ооруларынын классификациясы үчүн вейвлет трансформацияларын колдонгон моделдин матрицасынын катачылыгынын алынган жыйынтыктар келтирилген.



5-сүрөт. CNN технологияларын жана вейвлет өзгөртүүлөрүн колдонуу менен алынган картошка ооруларын алдын ала айтуу үчүн ROC жана AUC ийри сызыктарын талдоо

Корутунду

Бул изилдөө нейрондук тармактык моделдөөнү жана вейвлет өзгөртүүлөрүн моделдөөнү колдонгон заманбап гибридик моделдөө ыкмасын колдонгон, акыркы жылдары терең окутуу ыкмаларын колдонуу менен курулган моделдерди жакшыртуу үчүн кошумча курал катары алдыңкы орунду ээледі. Изилденип жаткан маалымат базасы катары PlantVillage маалымат топтому колдонулган. Сүрөттөрдө татаал жалбырак текстуралары жана ар кандай оорулардын белгилери камтылган. Вейвлет өзгөртүүлөрү бул өзгөчөлүктөрдү баса белгилөөдө өзгөчө натыйжалуу. Жыйынтыктар вейвлет өзгөртүүлөрү менен айкалыштырылган моделдер эн маанилүү натыйжаларды берерин, айрым оору учурлары үчүн 100% алдын ала айтуу тактыгын берерин көрсөтүп турат. Негизги эсептөөлөр NVIDIA GeForce RTX 4070 Ti SUPER GPUда жүргүзүлдү.

Колдонулган адабияттар

1. Кожобеков, К., Ракишева, Д., Пакал уулу, Д. (2025). Моделирование движения централизованно управляемых транспортных средств на перекрёстке с использованием методов искусственного интеллекта. *Вестник Ошского государственного университета*, (4), 276–289. https://doi.org/10.52754/16948610_2025_4_21
2. Downer, J. (2022). Effect of fertilizers on plant diseases - Topics in Subtropics - ANR Blogs. *Topics in Subtropics*. URL: <https://ucanr.edu/blogs/blogcore/postdetail.cfm?postnum=12364>
3. Ishengoma, F.S., Rai, I.A., Ngoga, S.R. (2022). Hybrid convolution neural network model for a quicker detection of infested maize plants with fall armyworms using UAV- based images. *Ecological Informatics*, 67, <https://doi.org/10.1016/j.ecoinf.2021.101502>
4. Jackson, T. *Northern corn leaf blight, Nebraska Extension* G2270 (2015) 1-4. Crops, Plant Diseases.
5. Onwunali, M.R.O., Mabagala, R.B. Assessment of yield loss due to northern leaf blight in ve maize varieties grown in Tanzania, *Journal of Yeast and Fungal Research*, 11 (1), 37–44. <https://doi.org/10.5897/jyfr2017.0181>
6. Pethybridge, S.J., Nelson, S.C. (2015). Leaf doctor: a new portable application for quantifying plant disease severity, *Plant Dis.* 99 (10), 1310–1316, <https://doi.org/10.1094/PDIS-03-15-0319-RE>
7. Riehle, D., Reiser, D., Griepentrog, Hans W. (2020). Robust index-based semantic plant/background segmentation for RGB- images. *Computers and Electronics in Agriculture*, 169, <https://doi.org/10.1016/j.compag.2019.105201>
8. Rouf Shah, T., Prasad, K., & Kumar, P. (2016). Maize - A potential source of human nutrition and health: A review. *Cogent Food & Agriculture*, 2(1). <https://doi.org/10.1080/23311932.2016.1166995>
9. Tomar, V., Singh, D., Dhillon, G.S., Chung, Y.S., Poland, J., Singh, R.P., Joshi, A.K., Gautam, Y., Tiwari, B.S., Kumar, U. (2021). Increased Predictive Accuracy of Multi-Environment Genomic Prediction Model for Yield and Related Traits in Spring Wheat (*Triticum aestivum* L.). *Front. Plant Sci.* <https://doi.org/10.3389/fpls.2021.720123>