

Modellashtirish natijalari quyidagi jihatlar bo'yicha taqqoslanishi mumkin [6]:

Parametrlar	Analitik yechim	Sonli yechim	Xatolik (%)
To'lqin tezligi V_0	1500 m/s	1485 m/s	1.0 %
To'lqin soni k	0.10 rad/m	0.102 rad/m	2.0 %
Dispersiya parametri α	0.05	0.052	4.0 %

Taqqoslashdan ko'rinib turibdiki, analitik yechim va sonli modellashtirish natijalari orasidagi farq 1-4% oralig'ida bo'lib, bu uslub asosida olingan natijaning yuqori aniqlikda olish imkoniyatini bildiradi.

Ushbu matematik modellarda olingan analitik yechimlar sonli natijalar bilan ma'lum darajada mos keladi, matematik jihatdan sodda ko'rinishga ega bo'lib, olingan natijalar geofizik tadqiqotlarda, seysmik to'lqinlarni tahlil qilishda va qurilish sohasida qo'llanishi mumkin. Lekin murakkab dispersiya effektlarini to'liq qamrab ololmagan va ba'zi yuqori chastotali to'lqin xatti-harakatlari e'tibordan chetda qoldiradi. Bu usullar keyinchalik geofizik sinovlar, seysmik monitoring va yer osti strukturalarini aniqlashda keng qo'llanilishi mumkin bo'ladi. Shuningdek, ushbu ishda qovushqoqlik kabi parametrlarning modelga ta'siri bahol

anib, ularning energiya so'nishi jarayonlaridagi roli aniqlashtirishga ma'lum ma'noda erishildi. Shu asosda, to'lqin intensivligining pasayish sur'atlari va ularning turli material qatlamlari orqali o'tishdagi xatti-harakatlari tahlil qilindi [3].

Xulosa. G'ovak-elastik anizotrop muhitda to'lqinlarning tarqalishini o'rganish bugungi geofizika, muhandislik geologiyasi va seysmik tadqiqotlar uchun nihoyatda dolzarb hisoblanadi. Ushbu maqolada ushbu murakkab muhitda to'lqinlarning analitik modellarini yaratish, ularni tahlil qilish va sonli modellar bilan taqqoslash bo'yicha izlanishlar olib borildi. Analitik yondashuv asosida, g'ovak-elastik muhitning fizik parametrlariga (zichlik, elastiklik, viskozlik, g'ovaklik darajasi va boshqalar) bog'liq bo'lgan dispersiya munosabatlari keltirildi. Ushbu munosabatlar orqali to'lqin sonining chastotaga bog'liqligi analitik tarzda ifodalandi va formulalar orqali izohlandi. Bu esa, gibrid muhitlarda yuz beradigan dispersiya hodisalarini chuqurroq tushunish imkonini berdi. Sonli modellashtirish asosida olingan qiymatlar analitik yechimlar bilan solishtirildi. Tadqiqot natijalari shuni ko'rsatadiki, g'ovak-elastik muhitdagi to'lqinlarning analitik modellarini ishlab chiqish orqali nafaqat real fizik muhitni tahlil qilish, balki u asosida sonli modellashtirish jarayonlarini to'g'ri yo'naltirish mumkin bo'ladi.

Adabiyotlar

1. Sheriff R.E., Geldart L.P. Exploration Seismology. "Cambridge University Press". (2nd ed.). – Cambridge. 1995.
2. Achenbach J.D. Wave Propagation in Elastic Solids. "North-Holland". – Amsterdam. 1975.
3. Carcione J.M. Wave Fields in Real Media: Wave Propagation in Anisotropic, Anelastic, and Porous Media (2nd ed.). "Elsevier". –P. 520. Amsterdam. 2007.
4. Biot M.A. Theory of propagation of elastic waves in a fluid-saturated porous solid. // "The Journal of the Acoustical Society of America", 28(2), - P. 23. – New York: 1956.
5. Tsvankin I. Seismic Signatures and Analysis of Reflection Data in Anisotropic Media. "Elsevier". – Amsterdam. 2001.
6. Pride S.R., Berryman J.G. Linear dynamics of double-porosity and dual-permeability materials. "Geophysical Journal International". 155(2), 456–469. Oxford. 2003.

REZYUME. Mazkur maqolada g'ovak-elastik anizotrop muhitda to'lqinlarning tarqalish jarayonini ifodalovchi analitik modellar ko'rib chiqilgan. Bunday muhitlarda to'lqinlarning xatti-harakati Biot nazariyasiga asoslanib tahlil qilinadi. To'lqin tenglamalari chiqariladi, dispersiya munosabatlari aniqlanadi va anizotrop muhit parametrlarining to'lqin tarqalishiga ta'siri baholanadi.

РЕЗЮМЕ. В данной статье рассматриваются аналитические модели, описывающие процесс распространения волн в поро-упругой анизотропной среде. Поведение волн в таких средах анализируется на основе теории Биота. Выводятся волновые уравнения, определяются дисперсионные соотношения и оценивается влияние параметров анизотропной среды на распространение волн.

SUMMARY. This article discusses analytical models describing the wave propagation process in a porous-elastic anisotropic medium. The wave behavior in such media is analyzed based on Biot's theory. Wave equations are derived, dispersion relations are determined, and the influence of anisotropic medium parameters on wave propagation is evaluated.

КОМБИНИРОВАННЫЙ МЕТОД КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ОБУЧАЕМЫХ ВЕСОВЫХ КОЭФФИЦИЕНТОВ

К.К.Сейтназаров – доктор технических наук, профессор

А.О.Куралбаев – студент

А.Т.Султанбаева – студентка

Нукусский государственный технический университет

Б.К.Султанов – старший преподаватель

Институт военной авиации Республики Узбекистан

Таянч сўзлар: кўп зонали тасвирлар, классификация, белгиларни квантлаш, иккилик векторлар, вейвлет-трансформация, оғирлик коэффициентлари, аҳамият кўрсаткичи, масофавий зондлаш интерпретацияси.

Ключевые слова: многозональные изображения, классификация, квантование признаков, бинарные векторы, вейвлет-преобразование, весовые коэффициенты, показатель значимости, интерпретация ДЗЗ.

Key words: multispectral images, classification, feature quantization, binary vectors, wavelet transform, weighting coefficients, significance indicator, remote sensing interpretation.

Введение. Предлагаемый метод классификации базируется на вычислении оценок принадлежности

исследуемого объекта к классам, используя квантованные вейвлет-признаки и весовые коэффициенты,

основанные на показателях значимости. Такой подход обеспечивает не только повышение точности, но и позволяет реализовать контроль размерности признакового пространства, оптимизируя процесс распознавания объектов на космических снимках [1, 2].

Принятие решений в автоматизированных контролируемых методах классификации сводится к сравнению исследуемого образца с эталонными представителями классов объектов. Каждый объект, участвующий в процессе классификации обучающие и тестовые образцы, представляется вектором признаков $\bar{y} = (y^1, y^2, \dots, y^n)$, где n - количество используемых признаков. В настоящей работе предлагается метод, относящийся к разделу алгоритмов, основанных на вычислении оценок. Рассмотрим общую концепцию работы таких алгоритмов.

Для опорного множества $\omega = \{y_1, y_2, \dots, y_k\}$ выбирается функция расстояния между объектами по ω и пороговое значение ε . Если объект распознавания $\bar{x}$ сравнивается с объектом обучения $\bar{x}_i$ по ω и

$$\rho(\omega\bar{x}, \omega\bar{x}_i) < \varepsilon,$$

где ρ - функция расстояния, то $\bar{x}$ получает «голос» за тот класс, которому принадлежит $\bar{x}_i$. Решение принимается по большинству голосов для всех опорных множеств и объектов обучения. Для этого на множестве обучающих векторов определяются минимальное и максимальное значения каждого признака и принимаются за левую и правую границы диапазона принимаемых значений [3, 4]:

$$d_p = [\min_{i=\bar{l}, l} (y_i^p); \max_{i=\bar{l}, l} (y_i^p)], p = \bar{l}, \bar{n}$$

где l - объем обучающей выборки. Полученные диапазоны d_p разбиваются на t равных сегментов.

При квантовании каждому объекту по i -му признаку соответствует набор $\bar{x} = (x_1^i, x_2^i, \dots, x_t^i)$, где $x_j^i = 1$, если

значение признака попадает в сегмент j , иначе — 0. Если значение выходит за диапазон d_p , единица присваивается граничному элементу — x_1^i или x_t^i . Такой подход дискретизирует непрерывные признаки y^i в бинарные векторы, унифицируя их масштаб и формат. Это также позволяет выполнить теоретическую оценку объема контрольной выборки [5, 6]. Таким образом, один объект обучения задается вектором:

$$\bar{x} = (x_1^1, x_1^2, \dots, x_1^t; x_2^1, x_2^2, \dots, x_2^t; \dots; x_n^1, x_n^2, \dots, x_n^t), \text{ где } \sum_{j=1}^t x_j^i = 1, i = \bar{l}, \bar{n}$$

В результате этапа обучения каждый класс распознавания C_k задается набором векторов соответствующих обучающих образцов. То есть, классу C_k соответствует объединение $\bigcup_{s=1}^k \bar{x}_s \rightarrow \bar{x}_k$, где l - количество объектов обучения, принадлежащих C_k . Процедура классификации нового объекта распознавания $\bar{x}$, представленного в виде, сводится к сравнению $\bar{x}$ с векторами $\bar{x}_s$ обучающей выборки. При совпадении $\bar{x}^i$ с $\bar{x}_s^i$ ($\bar{x} \in C_k$)

объект x получает голос за класс C_k . Суммарное количество голосов по всем признакам определяет оценку принадлежности F_k объекта $\bar{x}$ каждому классу C_k , $k = \bar{l}, \bar{M}$. В результате объект относится к тому классу, для которого оценка F_k максимальна [7, 8].

Дискретный вид таблицы обучения позволяет получить оценки качества распознающего алгоритма в рамках теории минимизации эмпирического риска.

Емкостью h семейства алгоритмов $F(\bar{x}, \alpha)$ (решающих правил), где α - индекс правила, называется максимальный объем выборки, которую можно разделить на два класса всеми возможными 2^h способами с помощью алгоритмов семейства $\{F(\bar{x}, \alpha)\}$. Если h конечна, то для правила $F(\bar{x}, \alpha)$, у которого эмпирический риск на случайной выборке объема L равен $\rho_\alpha(\alpha)$, выполнено

$$P(|\rho(\alpha) - \rho_\alpha(\alpha)| < \varepsilon) > 1 - \eta$$

где $\rho_\alpha(\alpha)$ - вероятность ошибки алгоритма $F(\bar{x}, \alpha)$, на всем пространстве объектов распознавания; $\varepsilon > 0$, $1 - \eta$ - заданная надежность. При этом объем выборки L и оценка точности ε связаны соотношением $L \sim \frac{h - \ln \eta}{\varepsilon}$.

Если пространство объектов распознавания конечно, то оценка остается справедливой для величины L , для которой $L \sim \frac{\ln N - \ln \eta}{\varepsilon}$.

где N - число различных, то есть, дающих разную классификацию, решающих правил семейства $\{F(\bar{x}, \alpha)\}$. Таким образом, в данном случае аналогом емкости выступает число $\ln N$ [13, 14]. Для предложенного описания векторов обучения число различных решающих правил не превосходит величины $t \cdot n \cdot 1$. Следовательно, уклонение вероятности ошибки от частоты ошибки оценивается величиной $\frac{\varepsilon_{\ln t}}{L}$ пропорциональной $\frac{n \cdot \ln t}{L}$. Другими словами, $L \sim \frac{n \cdot \ln t}{\varepsilon}$.

Объем контрольной выборки L оценивается величиной $h = n + 1$, где n - размерность пространства признаков. Опишем предложенный метод классификации в алгоритмическом виде. Обучение метода классификации [9]:

1. Ввод данных.

Обучающие векторы признаков:

$$\begin{aligned} &\bar{x}_{11}, \bar{x}_{12}, \dots, \bar{x}_{1/\bar{l}}; \\ &\bar{x}_{21}, \bar{x}_{22}, \dots, \bar{x}_{2/2}; \dots, \text{ где } \bar{x}_{ij} = (x_{ij}^1, x_{ij}^2, \dots, x_{ij}^n) \\ &\dots \\ &\bar{x}_{M1}, \bar{x}_{M2}, \dots, \bar{x}_{M/M}; \end{aligned}$$

где M - количество классов; l_i - количество обучающих образцов i -го класса; n - количество признаков.

Количество сегментов: t .

2. Формирование диапазонов значений признаков.

$$d_1 = [a_1, b_1], a_1 := \min_{ij} x_{ij}^1, b_1 := \max_{ij} x_{ij}^1$$

$$\dots$$

$$d_n = [a_n, b_n], a_n := \min_{ij} x_{ij}^n, b_n := \max_{ij} x_{ij}^n$$

3. Сегментирование диапазонов значений признаков.

$$\begin{aligned} d_1 &= [d_{10}, d_{12}, \dots, d_{1t}], d_{10} := a_1, d_{12} := a_1 + h_1, \dots, d_{1t} \\ &= b_1, h_1 = \frac{b_1 - a_1}{t} \end{aligned}$$

$$\dots$$

$$d_n = [d_{n1}, d_{n2}, \dots, d_{nt}], d_{n0} := a_n, d_{n2} := a_n + h_n, \dots, d_{nt} = b_n, h_n = \frac{b_n - a_n}{t}$$

4. Построение вспомогательных бинарных массивов распределения значений признаков по сегментам U^i ($i = \bar{l}, \bar{n}$) размером $M \times t$.

Для $i = 1, \dots, n$:

Для $j = 1, \dots, M$:

$$U_{js}^i = \begin{cases} 1, & \text{если значение хотя бы одного образца} \\ & j \text{ го класса попадает в сегмент } s \\ 0, & \text{иначе} \end{cases}$$

5. Построение массивов достоверностей $\mu^i (i = \bar{1}, \bar{n})$ размером $M \times t$ Для $i=1, \dots, n$:

$$\mu^i = \frac{m_{js}^i}{\sum_{j=1}^M m_{js}^i}, j = \bar{1}, \bar{M}; s = \bar{1}, \bar{t},$$

Таким образом, результатом обучения классификатора являются массивы $U^i (i = \bar{1}, \bar{n})$, описывающие распределение значений признаков по сегментам, а также массивы достоверностей.

Этап принятия решения:

1. Ввод данных.

Вектор признаков тестового образца:

$$\bar{y} = (y_1, y_2, \dots, y_n).$$

2. Формирование бинарных векторов распределения значений признаков по сегментам

$$\bar{v} = (v_{ij})_{i=\bar{1}, \bar{n}; j=\bar{1}, \bar{t}} := (0, 0, \dots, 0)$$

Для $i=1, \dots, n$:

если $y_i \in [d_{ij}, d_{i,j+1}) (j = \bar{0}, \bar{t} - \bar{1})$, то $v_{ij} := 1$.

3. Расчёт оценок принадлежности тестового образца к исследуемым классам объектов.

Для $j=1, \dots, M$:

$$\Phi_j = \sum_{i=1}^n \sum_{s=1}^t v_{is} \cdot \mu_{js}^i$$

4. Принятие решения о принадлежности тестового образца к классу объектов.

Образец относится к классу с номером p , где

$$\Phi_{p\bar{j}} = \bar{1}, \bar{M} \Phi_j$$

Наиболее известным методом уменьшения признакового пространства является метод главных компонент. Суть метода главных компонент (Principal Component Analysis (PCA)) состоит в следующем. Набор эталонов представляется матрицей X размером $n \times m$, где n - количество эталонов, m - количество признаков, которыми они описываются. Используются новые формальные переменные $s_a (a=1, \dots, A)$, которые являются линейными комбинациями исходных переменных $x_i (i=1, \dots, m)$, то есть, определяются формулами типа [10]:

$$s_a = p_{a1}x_1 + \dots + p_{am}x_m$$

С помощью новых переменных матрица X представляется произведением двух других матриц S и P . То есть,

$$X = SP^1 + E = \sum_{a=1}^A s_a p_a^t + E,$$

где $S (n \times A)$ называют матрицей счётов, $P (A \times m)$ матрицей нагрузок, E - матрицей остатков ($n \times m$). В результате получаем, что вместо переменных x_i исходная матрица X представима переменными t_a , которые и называют главными компонентами.

В настоящей работе для отбора признаков используется формула, представленная в работе и предназначенная для классификации объектов в базах данных.

$$F = 1 - \left(\sum_{i=1}^M \frac{\sum_{j=1}^t (u_{ij} \cdot \sum_{k=1, k \neq j}^t u_{kj})}{\sum_{j=1}^t u_{ij}} \right) / (M \cdot (M - 1)),$$

где M - количество классов, t - количество сегментов, на которое разбиты диапазоны значений признаков. Показатель значимости признаков является характери-

стикой, которая оценивает то, насколько хорошо признак разделяет классы. Эта характеристика может принимать значения от 0 до 1, где 0 означает, что признак не обладает разделяющей способностью, а 1 - признак обладает максимальной разделяющей способностью с точки зрения предложенной оценки значимости. Показатель значимости равный единице означает, что значения рассматриваемого признака для разных классов попадают в разные сегменты.

Допустим, исследуется 3 класса объектов, а разбиение проводилось на 6 сегментов, и для некоторого признака был получен следующий массив u :

$$110000 \\ u = (001100) \\ 000011$$



Рисунок 1 - Блок-схема предложенного метода интерпретации космических снимков

То есть, значения рассматриваемого признака эталонов класса 1 попадают в сегменты 1,2, эталоны класса 2-в сегменты 3,4, а эталоны класса 3-в сегменты 5,6. Рассчитаем показатель значимости:

$$F = 1 - \left(\frac{1 \cdot 0 + 1 \cdot 0 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1}{2} + \frac{0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1}{2} + \frac{0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 1 \cdot 0 + 1 \cdot 0}{2} \right) / (2 \cdot 3) = 1 - \frac{0}{6} = 1$$

Таким образом, признак, представимый для рассматриваемого набора классов массивом u , обладает максимальной значимостью.

Рассмотрим противоположный случай, когда значения признака по всем классам максимально разбросаны. Тогда массив u примет вид:

$$111111 \\ u = (111111) \\ 111111$$

Рассчитаем показатель значимости:

$$F = 1 - \left(\frac{1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2}{2} + \frac{1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2}{2} + \frac{1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2 + 1 \cdot 2}{2} \right) / (2 \cdot 3) = 1 - \frac{6}{6} = 0$$

Таким образом, описанный показатель значимости признаков позволяет оценивать разделимость классов по каждой характеристике в выбранной системе признаков. Важным параметром является количество сегментов разбиения диапазонов значений.

Заключение. Разработанный метод классификации многозональных изображений, основанный на бинарных векторах признаков, представляет собой эффективный инструмент для распознавания объектов, особенно при высокоразмерных признаковых пространствах. Ключевыми особенностями метода являются квантование признаков по сегментам, что позволяет учитывать особенности локальной структуры изображения, улучшая точность классификации на

уровне малых участков. Представление объектов в виде бинарных векторов упрощает вычисления и позволяет эффективно работать с большими объемами данных, при этом не теряя важной информации о структуре объектов. Применение показателя значимости признаков для их отбора и взвешивания при принятии решений позволяет повысить точность модели, исключая менее информативные признаки и фокусируясь на наиболее значимых для конкретной задачи.

Литература

1. Лопатин Е.В. Методы дистанционного зондирования для оценки растительности. -Москва: «Наука», 2019.
2. Usmanov R.N., Seitnazarov K.K. The problem of information model development for the relationship between hydrogeological object and its fuzzy-deterministic model. //The Advanced Science Journal. USA. 2014. Т. 7. – С. 67-73.
3. Усманов Р. Н., Сеитназаров К. К. Об организации параллельных вычислений в процессе решения геофиль-трационных задач. //Вестник ТУИТ. 2014. Т. 1. -С. 101-106.
4. Сеитназаров К.К. и др. Обзор методов получения космических изображений с высоким разрешением. // «Наука и общество». – С. 28.
5. Тюменцев А.И. и др. Выявление геоморфологических особенностей рельефа по данным дзз как поискового признака месторождений.//Известия Тульского государственного университета. Науки о земле. 2024. №.3. -С. 96-103.
6. Сеитназаров К.К., Турдышов Д.Х., Туремуратова Б.К. Обзор методов получения космических изображений с высоким разрешением. // «Наука и общество»
7. Kuenzer C., Dech S. "Remote Sensing Time Series – Revealing Land Surface Dynamics". Springer, 2016.
8. Seitnazarov K. et al. Hydrogeological-Mathematical Model of Formation and Management of Resources and Quality of Fresh Underground Water of the Karakalpak Artesian Basin //2021 International Conference on Information Science and Communications Technologies (ICISCT). IEEE, 2021. -P. 01-05.
9. Ткаченко В.Н. Основы дистанционного зондирования Земли. -Санкт-Петербург: Политехника, 2020.
10. Seitnazarov K.K., Aytanov A.K., Dosymbetov A.M. Strategy for Organization of Computational Experiments of the Functioning of Underground Water Inlets Using a Fuzzy Multiple Approach //2020 International Conference on Information Science and Communications Technologies (ICISCT). IEEE, 2020. -P. 1-6.

РЕЗЮМЕ. Мақолада вейвлет-белангилар ва уларни квантлашдан фойдаланган ҳолда классификация алгоритмларига асосланган кўп зонали тасвирларни интерпретация қилиш усули таклиф этилади. Белгилар қиймат оралиғини сегментларга ажратиш орқали иккилик векторларга айлантирилади, сўнгра синфга тегишлилик баҳоларини ҳисоблаш усули орқали қарор қабул қилинади. Ушбу ёндашувнинг ўзига хос жиҳати - белги аҳамия-тини ифодаловчи кўрсаткични қиритишдан иборат бўлиб, у белгиларнинг ажратувчанлик қобилиятини ҳисобга олади ва уларни танлаш мезони, шунингдек оғирлик коэффициенти сифатида ишлатилади.

РЕЗЮМЕ. В статье предложен метод интерпретации многозональных изображений, основанный на алгоритмах классификации с использованием вейвлет-признаков и их квантования. Признаки преобразуются в бинарные векторы с помощью сегментирования диапазонов значений, после чего принимается решение по методу вычисления оценок принадлежности к классам. Особенностью подхода является введение показателя значимости признаков, который учитывает разделяющую способность характеристик и используется как критерий их отбора, а также в качестве весового коэффициента.

SUMMARY. This article proposes a method for interpreting multispectral images based on classification algorithms using wavelet features and their quantization. The features are transformed into binary vectors through value range segmentation, followed by decision-making using class membership estimation. A distinctive aspect of the approach is the introduction of a feature significance indicator that considers the discriminative power of the characteristics and is used both as a selection criterion and as a weighting factor.

PARAMETRGE BAYLANISLI ŪSHINSHI DAREJELI TEŇLEMELERDI SHESHIWDE GEOMETRIYALIQ USIL

K.X.Seydullaev – *ülken oqıtıwshı*

Berdaq atındağı Qaraqalpaq mámleketlik universiteti

A.K.Seidullaev – *fizika-matematika ilimleri boyınsha filosofiya doktori, docent*

Ózbekistan Respublikası İlimler akademiyası V.I.Romanovskiy atındağı Matematika instituti

J.T.Amangeldieva – *student*

A.O.Jumamuratova – *student*

Berdaq atındağı Qaraqalpaq mámleketlik universiteti

Tayanch so‘zlar: Kardano formulasi, uchinchı darajalı ko‘phad, ekstremum nuqtalari, funksiya grafiklari.

Ключевые слова: формула Кардано, многочлен третьей степени, точки экстремума, графики функций.

Key words: Cardano's formula, third-degree polynomial, extremum points, function graphs.

Kirisiw. Jámiyet rawajlanıwı menen ilim hám texnikanıń túrlı tarawlarında matematikalıq modellestiriw hám máselelerdi sheshiw zárúrlıgı artıp barmaqta. Bul processte polinomlar hám olarğa baylanisli teñlemelerdi sheshiw áhmiyetli orın iyeleydi. Mektep matematika

kursınan belgili bolğanınday, ekinshi dárejeli kópag-zalırlarğa saykes keletuǵın kvadrat teñlemelerdi sheshiwdiń anıq hám isenimli usılları bar [1, 4]. Bul usıllar kóp-aǵzalınıń korenlerin (sheshimlerin) tabıwǵa imkaniyat beredi.