

Рис. 3 Распределение суммарного объема частиц V (а) и среднего размера частиц $d_{ср}$ (б) по глубине никотрированного слоя: 1-1 тип слоя; 2-2 тип слоя; 3-3 тип слоя

В результате металлографического анализа, усталостных испытаний и энергетической оценки ресурса никотрированных слоев трех типов выбран оптимальный вариант, которым является 2-й тип покрытия, т.е. вариант 4-х часового насыщения.

Литература

1. Арцыбашева Н.Н., Дерешов Д.С. Особенности поведения малых трещин в гетерогенных системах// В сб. Проектування, виробництво та експлуатація автотранспортних засобів і поїздів. Вып.7,- Львів: 2003. С.9-11.
2. Становский А.Л., Арцыбашева Н.Н., Меснянкин О.В. Влияние гетерогенности на усталостную прочность конструкционной стали. – Львів: Асоціація «Автобус» -1999. С. 161-164.

ОПТИМИЗАЦИЯ РАСПОЗНАВАНИЯ АНСАМБЛЕМ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ В УСЛОВИЯХ ВЫСОКОЙ СТЕПЕНИ НЕОПРЕДЕЛЕННОСТИ

Алёшин С.П.

*Кандидат технических наук, доцент
Полтавского национального технического университета
имени Юрия Кондратюка,
Украина, г. Полтава*

Бородина Е.А.

*Старший преподаватель
Полтавского национального технического университета
имени Юрия Кондратюка,
Украина, г. Полтава*

OPTIMIZATION OF THE RECOGNITION OF ANSEMBLE NETWORK MODELS IN THE CONDITIONS OF HIGH DEGREE OF UNCERTAINTY

Aleshin S.

*Candidate of Engineering Sciences, Associate Professor
Poltava National Technical Yuri Kondratyuk University,
Ukraine, Poltava*

Borodina E.

*Senior Lecturer,
Poltava National Technical Yuri Kondratyuk University,
Ukraine, Poltava*

Аннотация

Рассмотренная автоматизация отбора результатов нейронных сетей, позволила провести исследование в создании алгоритмического и программного инструментария, что предоставило возможность минимизировать материальные и финансовые ресурсы.

Abstract

The automation of the selection of the results of neural networks considered allowed to conduct research in the creation of algorithmic and software tools, which provided an opportunity to minimize material and financial resources.

Ключевые слова: распознавание, обучение, адаптация, алгоритм, нейронная сеть, информативность факторов, принятие решений.

Keywords: recognition, training, adaptation, algorithm, neural network, informative factors, decision making.

Постановка проблемы. При принятии решений группой экспертов вес каждого голоса учитывается индивидуально (квалификация, образование, опыт работы и т.д.) и в реальных условиях управления объектами и процессами консенсус достигается на основании общепринятых методик и правил [1,2]. Однако, при разработке автоматизированных СППР, когда решающее правило должно быть формализовано, встроено в алгоритм формирования и актуализации данных и обеспечивать оптимальные оценки, требуется дополнительная технология. Это особенно проявляется при работе со сложными объектами, которые характеризуются входными факторами и выходными состояниями высокой размерности со слабо формализованными и нечетко обусловленными взаимосвязями [3]. Как показано в ряде работ [4,5], в этих условиях энтропия системы зависит от количества контролируемых состояний, а те, в свою очередь, определяются набором параметров некоторой размерности. В результате система распознава-

ния состояний объекта исследования вынуждена функционировать в условиях высокой степени энтропии за счет высокой размерности анализируемого пространства признаков. С другой стороны, эти состояния, для указанных условий, приобретают характер равновероятных, что дополнительно подчеркивает существование высокой неопределенности при принятии решений[6,7].

Современные технологии поддержки принятия решений в условиях информатизации экономики в качестве экспертов позволяют применить обученные искусственные нейронные сети, автоматизируя процедуры проверки гипотез при реализации коллективных статистических решающих правил [8,9]. Однако, достичь высокую достоверность откликов для ансамбля моделей в отмеченных условиях, удастся не всегда. Требуется автоматизировать отбор результатов нейронных сетей по анализу их откликов и при этом обеспечить оптимальность на уровне известных статистических решающих правил. Решение этой задачи позволит исключить субъективность в принятии решений (человеческий фактор) и обеспечить их оптимальность практически в режиме реального времени.

Анализ аспектов сложности объектов исследования

Ранее было отмечено, что сложным считается объект, обладающий входными факторами и выходными состояниями высокой размерности со слабо формализуемыми и нечетко обусловленными взаимосвязями и высокой степенью априорной неопределенности. Энтропия подобной системы монотонно возрастает с ростом ее состояний, но главное – уже при двух альтернативах энтропия стремится к максимуму, а вероятность оценки состояния к 0,5. Очевидно, что принятие решения в этих условиях (50 на 50) не конструктивно.

Данный вывод не противоречит результатам анализа известных исследователей сложных систем (Бусленко Н.П., Растринин Л.А., Коваленко И.Н. и др. [1,2]) однако позволяет четко выделить факторы сложности (слабо формализуемые и не четко обусловленные внутренние взаимосвязи входных факторов и состояний системы при высокой степени исходной априорной неопределенности). В эту категорию попадает широкий класс объектов в предметной области (медицинская и техническая диагностика, экономический и экологический мониторинг, разведка полезных ископаемых и др.) с массивами данных, где знания об объекте представлены в неявном виде, но позволяют формировать обучающие выборки. Однако для принятия решений в границах требуемой точности и за приемлемое время требуется построение адекватной мат. модели исследуемой системы в конкретной предметной области, что при отмеченных выше условиях – проблема. Именно поэтому предполагается конструировать массив нейросетевых моделей различной архитектуры, методов обучения, размерности слоев и элементов, мощности обучающей выборки и внутренних параметров моделей[8]. Представив ансамбль моделей в основном программном коде как

отдельные приложения, получаем модели независимых экспертов-классификаторов в данной области.

Если считать, что все n событий равновероятны, то формула оценки неопределенности (энтропии) состояний по Шеннону упрощается и приобретает вид формулы Хартли:

$$H = \sum_{i=1}^n p(i) \log_2(p(i)) \rightarrow H = \log_2 n$$

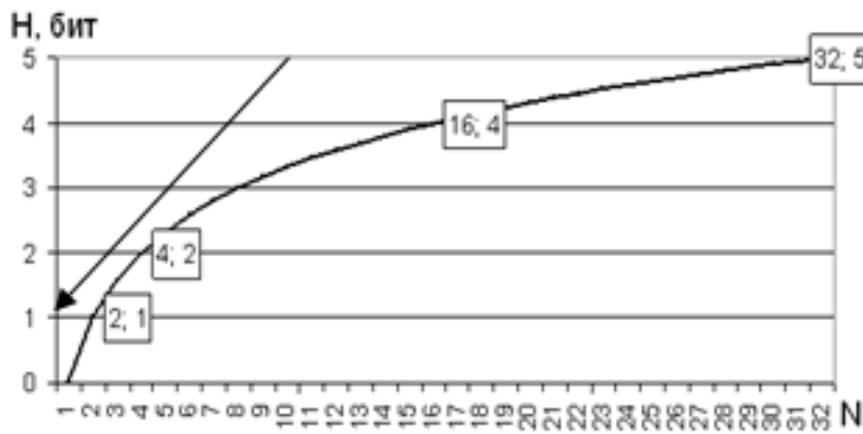


Рисунок 1. Соотношение энтропии и числа состояний

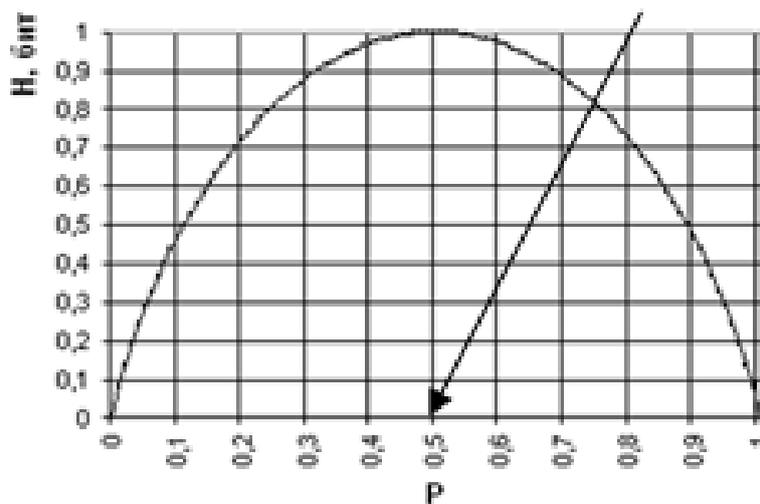


Рисунок 2. Рабочая область анализа

На рис. 1 показано, что энтропия системы не только растет от числа состояний объекта исследования, но и равна единице уже при двух возможных состояниях. А рис. 2 отображает ситуацию, когда рабочая область возможных вероятностей событий (состояний) в диапазоне между достоверностью ($p=1$) и невозможностью ($p=0$) будет тяготеть к равновозможной области ($p=0.5$).

При этом один аспект сложности связан с количеством анализируемых состояний и соответствующим числом контролируемых эти состояния параметров. Второй аспект связан с фактором времени – как быстро распознается состояние системы (снимается неопределенность). Оба аспекта

взаимосвязаны. При анализе состояний (распознавании) последовательно уменьшается количество параметров, снижается энтропия, но этот процесс растягивается во времени пропорционально числу этих состояний.

$$H \approx V(n)t \quad (1)$$

Если, например, скорость распознавания с увеличением длины алфавита состояний падает по факториальному закону $V(n) \approx \frac{1}{n!}$, то время распознавания растет по закону $t_{расч} = \frac{\log_2 n}{V(n)}$ или $t_{расч} = n! \log_2 n$. (2)

Следовательно, высокая степень неопределенности и конечное время распознавания являются объективными факторами принятия решений экспертами (моделями) и выбор оптимального результата на основе анализа откликов всего ансамбля моделей, на наш взгляд, представляется конструктивным.

Формализация нейросетевого коллективного распознавания состояний

Рассмотрим формальный подход к построению схемы принятия нейросетевого коллективного решения в условиях решений, полученных каждой отдельной сетью в ансамбле. Необходимо показать, что при равновероятных классах коллективное решение продуктивнее индивидуального решения моделей ансамбля, а также обосновать правила, обеспечивающие оптимизацию среднего риска при принятии совместного решения.

Для автоматизации процесса принятия решений следует применить методы распознавания образов, когда реальные объекты представлены конечным набором информативных признаков, выполняющих роль предикторов в процессе синтеза разделяющей функции (поверхности), позволяющие автоматизировать процесс классификации.

Современные подходы к комплексированию решений разными субъектами (сетями) предполагают несколько вариантов. Например, метод взвешенного голосования [7] или информативного ранжирования [9] и др. В нашем случае решения приходится принимать в условиях высокой априорной неопределенности, с входным вектором признаков и состояний объекта высокой размерности и не строго определенных взаимосвязях входных факторов с текущими состояниями исследуемого объекта. Предполагается наиболее конструктивным для рассматриваемых объектов подход к решению данной задачи на основе коллективных статистических правил.

Постановка задачи

Пусть исследуемая ССТС (Z_s) находится в одном из M_s возможных состояний V_{1S}, \dots, V_{MS} с известными априорными вероятностями $P(V_{1S}), \dots, P(V_{MS})$, при условии

При отсутствии апостериорной информации состояние объекта (Z_s) классифицируется исходя из известной наибольшей априорной вероятности выбора того или иного класса.

Величина $P_{0iu} = 1 - \max\{P(V_{1S}), \dots, P(V_{MS})\}$, определяет минимальную вероятность ошибки распознавания состояния объекта.

Пусть имеется N обученных нейронных сетей из ансамбля моделей A_1, \dots, A_N . Нейронные сети, независимо друг от друга, классифицируют состояние объекта (Z_s). Этот факт фиксируется принятием решения $\delta_i(Z_s)$, которое представлено присвоением ему некоторой индикаторной функции $\delta_i(Z_s) = k$. Это справедливо, когда сеть A_i выдает решение в пользу состояния V_k , где $i = 1, \dots, N$, $k = 1, \dots, M$, а N и M – число сетей и классов состояний соответственно.

Аналитические возможности каждой i -й модели из ансамбля оценим вероятностью $P(A_i)$ по результатам предварительного обучения. Так как предварительное обучение имеет целью проверить работоспособность моделей без оптимизации параметров и режимов их работы, то правомерно утверждение, что $P(A_i) < P_0$ для всех $i = 1, \dots, N$.

При таких условиях необходимо построить коллективное решающее правило, интегрирующее частные решения задачи распознавания каждой нейронной сетью, которое минимизирует средний риск (вероятность) ошибочной классификации.

Логика коллективного решающего правила для ансамбля нейромоделей

Для простого случая, когда число обученных моделей $N = 2$, а количество возможных состояний объекта $M = 2$ (например, болен-здоров, кредитоспособен-некредитоспособен, устойчив-неустойчив, исправно-неисправно и т.д.). Для этого примера возможны четыре комбинации откликов нейросетей:

$$S_{11} : \delta_1(Z_s) = 1, \delta_2(Z_s) = 1, \text{ да} - \text{ да};$$

$$S_{12} : \delta_1(Z_s) = 1, \delta_2(Z_s) = 2, \text{ да} - \text{ нет};$$

$$S_{21} : \delta_1(Z_s) = 2, \delta_2(Z_s) = 1, \text{ нет} - \text{ да};$$

$$S_{22} : \delta_1(Z_s) = 2, \delta_2(Z_s) = 2, \text{ нет} - \text{ нет}.$$

Как видно в ситуациях S_{12} и S_{21} отклики сетей не совпадают по логике реакции. Чтобы принять оптимальное решение в этой ситуации не достаточно принять решение сети с меньшей ошибкой, так как в общем случае такой подход неправомерен [8]. Если оценить условные (апостериорные) вероятности $P\left(\frac{V_{1S}}{S_{12}}\right)$ и $P\left(\frac{V_{2S}}{S_{12}}\right)$ состояний объекта в ситуации S_{12} , то для оптимизации средней вероятности ошибки распознавания следует принимать результирующее решение в пользу состояния V_{1S} , если

$$P\left(\frac{V_{1S}}{S_{12}}\right) > P\left(\frac{V_{2S}}{S_{12}}\right) \quad (3)$$

Если же выполняется обратное соотношение

$$P\left(\frac{V_{1S}}{S_{12}}\right) < P\left(\frac{V_{2S}}{S_{12}}\right) \quad (4)$$

то принимается решение в пользу состояния V_{2S} . Если априорные вероятности $P(V_{1S}), \dots, P(V_{MS})$, измеряются, то применим известные выражения для алгоритма проверки гипотез при двух альтернативах [7]:

$$P\left(\frac{V_{1S}}{S_{12}}\right) = \frac{P(V_{1S}) \cdot P\left(\frac{S_{12}}{V_{1S}}\right)}{P(S_{12})}, \quad (5)$$

$$P\left(\frac{V_{2S}}{S_{12}}\right) = \frac{P(V_{2S}) \cdot P\left(\frac{S_{12}}{V_{2S}}\right)}{P(S_{12})}, \quad (6)$$

Подставим (5) и (6) в (3), получим соотношение

$$P(V_{1S}) \cdot P\left(\frac{S_{12}}{V_{1S}}\right) > P(V_{2S}) \cdot P\left(\frac{S_{12}}{V_{2S}}\right) \quad (7)$$

По определению условная вероятность $P\left(\frac{S_{12}}{V_{1S}}\right)$ есть вероятность того, что в ситуации, когда объект находится в состоянии V_{1S} , модель A_2 выдала правильный отклик, а модель A_1 – ошибочный. Так как модели в ансамбле обучались разными методами и имеют отличную архитектуру, число слоев и нейронов в слое, а так же могут обучаться на разных подмножествах генеральной выборки, то их отклики можно обоснованно считать независимыми [8]. Это условие позволяет корректно применить формулу произведения вероятностей [7] и получить два соотношения

$$P\left(\frac{S_{12}}{V_{1S}}\right) = P(A_2)[1 - P(A_1)] \quad (8)$$

и

$$P\left(\frac{S_{12}}{V_{2S}}\right) = P(A_1)[1 - P(A_2)] \quad (9)$$

Тогда соотношение (5), с учетом (6), (7), (8) и (9), можно представить в виде:

$$P(V_{1S}) \cdot P(A_2)[1 - P(A_1)] > P(V_{2S}) \cdot P(A_1)[1 - P(A_2)] \quad (10)$$

Из (10) следует, что в ситуации S_{12} (ошибка первого рода), когда отклики сетей ансамбля противоречивы, состояние объекта Z_S следует относить к классу V_{1S} только в случае, когда

$$P(A_2) > \frac{\lambda \cdot P(A_1)}{1 - P(A_1) \cdot (1 - \lambda)}, \quad (11)$$

где $\lambda = \frac{P(V_{2S})}{P(V_{1S})}$ – отношение априорных вероятностей оценки состояний

(классов) объекта исследования.

Когда соотношение (11) меняется на обратное

$$P(A_2) < \frac{\lambda \cdot P(A_1)}{1 - P(A_1) \cdot (1 - \lambda)}, \quad (12)$$

то в ситуации S_{12} состояние объекта Z_S следует относить к классу V_2 .

Проводя аналогичные рассуждения, не трудно показать, что в ситуации S_{21} (ошибка второго рода), решение в пользу принятия состояния объекта класса V_1 принимается в том случае, когда

$$P(A_1) > \frac{\lambda \cdot P(A_2)}{1 - P(A_2) \cdot (1 - \lambda)}, \quad (13)$$

а решение в пользу класса состояния объекта V_2 , принимается при условии

$$P(A_1) < \frac{\lambda \cdot P(A_2)}{1 - P(A_2) \cdot (1 - \lambda)}, \quad (14)$$

Пример реализуемости коллективного решающего правила

Выберем любые две строки в поле профилей обученных моделей и введем в формальный алгоритм числовые значения. Пусть $P(V_{1S}) = 0.4$, $P(V_{2S}) = 0.8$, тогда $\lambda = 2.00$. Далее пусть первая сеть ошибается в 5% случаев, то есть $P(A_1) = 0.05$, а вторая – в 9% случаев, то есть $P(A_2) = 0.09$. Предположим, что сеть (A_1) отнесла состояние объекта к классу V_{1S} , а вторая сеть (A_2) – то же состояние – к классу V_{2S} . Имеем два альтернативных решения в ситуации S_{12} .

Применим формулы расчета условных вероятностей, подставив числовые значения. Для проверки обоснованности решения в пользу класса V_{2S} . Определим условные апостериорные вероятности ситуации (S_{12}) для выбранных сетей из примера:

$$P(V_{1S} / S_{12}) = \frac{P(V_{1S}) \cdot P(S_{12} / V_{1S})}{P(S_{12})} = \frac{0,4 \cdot (1 - 0,05) \cdot 0,09}{0,4 \cdot (1 - 0,05) \cdot 0,09 + 0,8 \cdot (1 - 0,09) \cdot 0,05} = 0,486$$

и

$$P(V_{2S} / S_{12}) = \frac{P(V_{2S}) \cdot P(S_{12} / V_{2S})}{P(S_{12})} = \frac{0,8 \cdot (1 - 0,09) \cdot 0,05}{0,4 \cdot (1 - 0,05) \cdot 0,09 + 0,8 \cdot (1 - 0,09) \cdot 0,05} = 0,514$$

Так как $P\left(\frac{V_{1S}}{S_{12}}\right) < P\left(\frac{V_{2S}}{S_{12}}\right)$, исследуемый объект (или его состояние)

относится к классу V_{2S} и при этом нейронные сети лишь поставляют экспертные данные в алгоритм коллективной классификации.

Следовательно, алгоритм инвариантен способу получения входных данных. Это могут быть строгие аналитические расчеты, заключения экспертов или отклики нейросетевых моделей.

Это особенно важно, например, в деятельности коллективных систем принятия решений (ситуационных центров). При этом на основе препроцессинга по данным предыстории предметной области исследуемого объекта, априорные вероятностные характеристики могут быть получены по репрезентативным выборкам при наличии времени и информационного ресурса.

Тогда априорные вероятности $P(V_k)$ и $P(A_i)$ при достаточно большой выборке могут быть корректно определены из частот фактов:

$$P^*(V_k) = \frac{G_k}{G}, \quad P^*(A_i) = \frac{E_i}{G},$$

где G_k – общее число случаев фиксации k -го класса ($k = 1, 2$) в выборке из G наблюдений, а E_i – общее число ошибок i -й нейросети ($i = 1, 2$) в этом же массиве наблюдений.

Нетрудно убедиться в том, что аналогичные равенства имеют место и при других сочетаниях экспертов-моделей с различным качеством представляемых ими откликов.

Следовательно, если нейронные сети, как независимые эксперты, принимают решения об отнесении состояния объекта к тому или иному

классу, причем $P\left(\frac{A_{iS}}{V_1}\right) = P\left(\frac{A_{iS}}{V_2}\right)$

$$P(A_{iS}/V_1) = P(A_{iS}/V_2)$$

при $i = 1, 2$, то предлагаемая технология расчетов является оптимальной в данных условиях, так как обеспечивает минимум средней вероятности ошибочной классификации, что соответствует статистическому критерию идеального наблюдателя при проверке гипотез [7].

Таким образом, сравнение формального правила принятия коллективного решения группой экспертов и ансамблем нейронных сетей (при принятых по условию задачи ограничениях), подтверждает инвариантность статистического правила проверки гипотез к способу формирования априорных и апостериорных вероятностей оценки классов состояний объекта. С практической точки зрения это означает, что использование нейросетей из ансамбля обученных моделей для коллективного принятия решений при классификации состояний ССТС, позволяет обеспечить продуктивность результата не хуже продуктивности классического решающего правила Байеса [7].

Следовательно, автоматизация коллективного решающего правила при оценке состояний объектов с высокой степенью априорной неопреде-

ленности реально достижима, а строгое доказательство этого факта позволяет считать конечный результат состоятельным и технологичным.

Выводы:

1. Оптимизация распознавания состояний объекта с высокой степенью априорной неопределенности достигается применением коллективного статистического решающего правила адаптированного к ансамблю обученных искусственных нейронных сетей, каждый отклик которых рассматривается алгоритмом как голос эксперта. Это позволяет повысить объективность принятых решений за счет применения статистических решающих правил по данным моделей, обученных на репрезентативных выборках данных предыстории исследуемых объектов.

2. Нейронные сети обучены предварительно, помещены в базу данных и применяются непосредственно при обращении к ним по команде алгоритма. Это позволяет сократить время на принятие решения, чем обеспечивается его своевременность и релевантность.

3. Практическая значимость результатов исследования состоит в создании алгоритмического и программного инструментария на платформе современного пакета технического анализа данных Statistica 10 с последующим формированием самостоятельных приложений в основном программном коде, что позволяет минимизировать материальные и финансовые ресурсы разработчика.

Список использованной литературы

1. Д. Джарратано, Г. Райли. Экспертные системы. Принципы разработки программирования. Изд. Вильямс, 2006.

2. Бусленко Н.П. Моделирование сложных систем. 2-е изд. - М.: Наука, 1978.- 400с.

3. Морозов А.А. Состояние и перспективы нейросетевого моделирования СППР в сложных социотехнических системах / В.П. Клименко, А.Л. Ляхов, С.П. Алёшин // Математичні машини і системи. – 2010. - № 1.- С. 127 – 149.

4. Ляхов А.Л. Сложная социотехническая система как объект управления искусственной нейронной сетью / А.Л. Ляхов, С.П. Алёшин // Вісник інженерної академії України. – 2010. – № 1. – С. 93 – 97. Т

5. Ляхов А.Л. Интеллектуальный анализ данных в прикладных экономических задачах / А.Л. Ляхов, С.П. Алёшин // Науковий вісник Полтавського національного технічного університету. Економіка і регіон – 2009. - № 4(23). – С. 140 – 147.

6. Альошин С.П. Сложная система в категориях формализации, обусловленности и энтропии / С.П. Альошин // Збірник тез за матеріалами 12-й міжнародної науково-практичної конференції МОДС 2017 – Чернігів, 2017. – С. 92 – 94.

7. Вентцель Е.С. Теория вероятностей. Учебник для вузов.- М.: Наука, 1969. – 576с

8. Хайкин, С. Нейронные сети: Полный курс. 2-е издание / Хайкин С.. М.: "Вильямс", 2006.- 1104 с.

9. Галушкин А.И. Нейрокомпьютеры и их применение на рубеже тысячелетий в Китае. Т.1 и 2 / А.И. Галушкин. М., 2004.- 367+464 с.

ЭФФЕКТИВНАЯ ТЕХНОЛОГИЯ РЕЦИКЛИНГА ПЛАСТИКА

Мухамадеева Р.М.

*Кандидат технических наук, доцент
Кокшетауского университета им.Абая Мырзахметова*

Баязитова З.Е.

*Кандидат биологических наук, доцент
Кокшетауского университета им.Абая Мырзахметова*

EFFECTIVE RECYCLING TECHNOLOGY PLASTICS

Mukhamadeyeva R.

*Associate Professor
Kokshetau Abay Myrzakhmetov University
Kazakhstan, Kokshetau*

Bayazitova Z.

*Associate Professor
Kokshetau Abay Myrzakhmetov University
Kazakhstan, Kokshetau*

Аннотация

По результатам мониторинга состояния полигонов твердых бытовых отходов малых городов Ақмолинской области, был сделан вывод о необходимости разработки эффективной технологии переработки пластика. В статье предложен вариант модели установки криогенного измельчения пластиковой тары.

Abstract

After monitoring the condition of solid household waste landfills in small cities of the Akmola region, they proposed to develop an effective technology for the processing of plastics. The article suggests a variant of the model for the installation of cryogenic grinding of plastic containers.

Ключевые слова: вторичная переработка, пластиковая тара, криогенная технология

Keywords: recycling, plastic containers, cryogenic technology

В результате анализа мирового опыта переработки пластиковых бутылок в современных условиях, был сделан вывод, что проблема по степени актуальности будет нарастать, количество производимой пластиковой тары не будет прекращено в ближайшем десятилетии, новые технологии