

ИСПОЛЬЗОВАНИЕ АЛГОРИТМА ВЕРОЯТНОСТНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ИЗМЕРЕНИЯ УРОВНЯ КАЧЕСТВА ОБРАЗОВАНИЯ

DOI: 10.36724/2072-8735-2023-17-3-27-33

Manuscript received 14 February 2023;
Accepted 16 March 2023

Аль-Дулаими Омар Хатем Заидан,
 Воронежский государственный технический университет,
 г. Воронеж, Россия, oamar1982@yandex.ru

Ключевые слова: вероятностная нейронная сеть,
 классификация, успеваемость учащихся, качество
 образования

Традиционный метод определения качества образования слишком однозначен и необоснован, что не подходит для комплексной оценки способностей учащихся. Целью статьи является обоснование использования алгоритма вероятностной нейронной сети. Методы исследования. Достоверность представленных результатов обеспечивается анализом научной литературы, моделированием вероятностной нейронной сети, сравнительным анализом моделей и оценкой эффективности модели. Результаты исследований. В этой статье алгоритм вероятностной нейронной сети (PNN) используется для определения качества образования путем рассмотрения важного влияния между различными достижениями учащихся. Алгоритм PNN происходит от байесовского правила принятия решений и использует нелинейное окно Гаусса Парзена в качестве функции плотности вероятности. Поскольку модель PNN обладает сильными нелинейными и антиинтерференционными свойствами, она подходит для определения качества образования путем классификации достижений учащихся. Кроме того, в этой статье также обсуждается влияние различных моделей оценки на точность и эффективность классификации. Кроме того, также обсуждается влияние значения спреда на модель PNN. Область применения. Наконец, фактические данные используются для определения качества образования. Выводы. Экспериментальные результаты показывают, что точность обнаружения может достигать 95%, а время обнаружения составляет всего 0,0156 с на основе предложенного метода. То есть метод представляет собой очень практичный алгоритм обнаружения с высокой точностью и эффективностью. Кроме того, в нем также содержится информация о том, как еще больше улучшить качество преподавания. Доказано, что использование модели PNN позволяет точно классифицировать достижения студентов по критерию качества.

Для цитирования:

Аль-Дулаими Омар Хатем Заидан. Использование алгоритма вероятностной нейронной сети для измерения уровня качества образования // T-Comm: Телекоммуникации и транспорт. 2023. Том 17. №3. С. 27-33.

For citation:

Al-Dulaimi Omar Hatem Zaidan. Using a probabilistic neural network algorithm to measure the level of education quality. *T-Comm*, vol. 17, no.3, pp. 27-33. (in Russian)

1. Введение

С быстрым развитием информационных технологий многие университеты используют систему определения качества профессионального образования для оценки способностей студентов. Однако существующая система обнаружения недостаточна для эффективной оценки качества образования. В последние годы, с расширением высшего образования и быстрым ростом числа студентов, достижения студентов производят большое количество данных.

Таким образом, необходимо использовать комплексный метод многоракурсного обнаружения для замены обычного метода одиночного обнаружения. В настоящее время, с учетом реальных потребностей системы определения качества образования, она должна использовать передовые информационные технологии для получения эффективной оценки достижений учащихся и, таким образом, выявления корреляции между достижениями и способностями учащихся. То есть очень важно всесторонне и объективно оценивать качество образования на основе передового метода обнаружения. Важным средством определения качества образования является классификация достижений учащихся.

Его основная цель – построить правильную модель классификации для анализа эффективной информации, скрытой в достижениях учащихся. На данный момент существует множество методов классификации, таких как моментные инварианты [1], случайный лес [2,3], метод опорных векторов [4], анализ главных компонентов [5], марковские случайные поля [6], оптимизация роя частиц [7], дискретное вейвлет-преобразование [8] и др. Кроме того, в [9] предлагается новая структура сложного сетевого классификатора для решения проблемы классификации сетей, которая показывает, что предложенный метод хорошо работает в крупномасштабных сетях. В [10] он использует метод предметно-состязательного обучения для классификации текста с низкими ресурсами и может получить хорошие результаты. В [11] представлен метод обнаружения и классификации десяти коротких замыканий в распределительных сетях, что доказывает эффективность предложенного метода.

Предложен алгоритм распознавания изображений SAR путем объединения сверточной нейронной сети и алгоритма экстремальной обучающей машины, а точность распознавания изображений составляет 100%.

В этой статье модель PNN используется для классификации достижений учащихся. Экспериментальные результаты показывают, что предложенный метод может повысить эффективность классификации, чтобы улучшить качество обучения и способствовать реформе обучения. Оставшаяся часть статьи структурирована следующим образом: в разделе 2 вводится модель PNN и связанная с ней концепция. В разделе 3 приводится экспериментальный метод, обсуждения и анализ представлены на основе экспериментальных результатов. В разделе 4 дается заключение.

2. Вероятностный нейросетевой алгоритм

В технологии нейронной сети модель PNN использует экспоненциальную функцию для замены функции активации S-образной формы. Это нейронная сеть с прямой связью, которая подходит для классификации данных.

2.1. Основная концепция модели PNN

Структура PNN содержит четыре слоя, такие как входной слой, слой шаблона, слой суммирования и выходной слой. PNN структура показана на рисунке 1.

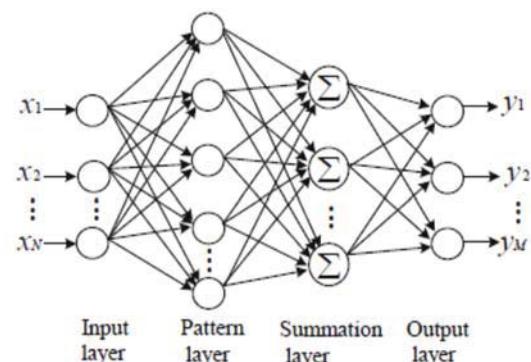


Рис. 1. Структура модели PNN

Эффект каждого слоя описан на рис. 2.

Слой шаблона: вычислить взвешенную сумму между входным слоем и скрытым слоем

Слой суммирования: суммирование и сопоставление шаблонов классификации и нейронов.

Выходной слой: выбор нейронов с максимальной апостериорной плотностью вероятности в качестве выходных данных из оцененных различных плотностей вероятности.

Рис. 2. Функции каждого слоя

К основным преимуществам модели PNN можно отнести следующие аспекты:

- (1) Простая структура и высокая скорость обучения, которая подходит для обработки данных в реальном времени.
- (2) Каждая обучающая выборка определяет нейрон скрытого слоя, и значение веса нейрона берется непосредственно из значения входной выборки.
- (3) Он может реализовать нелинейную аппроксимацию произвольно, результат классификации нечувствителен к форме базисной функции.
- (4) Каким бы сложным ни был процесс классификации, при наличии достаточного количества обучающих данных можно получить оптимальное решение по правилу байесовской классификации.

(5) Нет необходимости переобучать при добавлении новых образцов.

(6) Используйте алгоритм линейного обучения, чтобы выполнить задачу алгоритма нелинейного обучения. Кроме того, он также обладает такими достоинствами, как высокая точность классификации, хорошая расширяемость и хорошая отказоустойчивость и др.

Обычно базовый алгоритм PNN показан на рис. 3. Конечно, следует отметить, что PNN делает три предположения для функции плотности вероятности.

(1) Функция плотности вероятности каждой категории идентична.

(2) Функция плотности вероятности удовлетворяет распределению Гаусса.

(3) Вариационная матрица функции плотности вероятности распределения Гаусса является диагональной матрицей, и значения каждого диагонального элемента равны.

Модель PNN имеет хорошие характеристики, основанные на вышеупомянутых предположениях.



Рис. 3. Базовый алгоритм PNN

Конкретно алгоритм PNN можно описать следующим образом:

(1) Используйте каждую выборку в качестве вектора и постройте начальные обучающие векторы из исходных данных.

(2) Количество нейронов во входном слое равно размерности векторов признаков. Входные узлы — это просто узлы распределения, которые обеспечивают одинаковые входные значения для всех узлов шаблона, и векторы признаков передаются каждому узлу в слой узора. (3) Количество нейронов

в слое шаблона равно количеству входных выборок. Когда входные данные даны, он создаст вектор. На этом шаге оператор функции активации выражается как:

$$g(z_j) = \exp[(z_j - 1)/\sigma^2] \quad (1)$$

В уравнении (1) z_j является выходным значением. На этом шаге каждое значение входной выборки будет умножено на весовой коэффициент слоя шаблона. Выходное значение каждой единицы в слое шаблона выражается как:

$$f_A(x) = \sum \exp\left(-\frac{\|x - x_{ij}\|^2}{2\sigma^2}\right) \quad (2)$$

В уравнении (2), $x = [x_1, x_2, \dots, x_n]$ — входная выборка, X_{ij} — матрица весов между входным слоем и слоем шаблона, это означает, что j обучающая выборка принадлежит i категории, $i = 1, 2, \dots, M$, $j = 1, 2, \dots, N$ — общее количество проб, N — номер категории i . σ — коэффициент сглаживания, уникальное значение, которое можно регулировать. Как правило, σ устанавливается между 0 и 1.

Условная вероятность атрибуции выборки выражается функцией плотности вероятности.

$$f_A(x) = \frac{1}{(2\pi)^{n/2}} \frac{1}{m} \sum \exp\left[-\frac{\|x - x_{ij}\|^2}{2\sigma^2}\right] \quad (3)$$

В уравнении (3), n — размерность характеристических векторов пространства выборки, m представляет количество выборок, принадлежащих категории i . (4) Как показано в уравнении (4), слой суммирования соединяет все виды единиц слоя образца и выборочно добавляет вероятность, принадлежащую к одной и той же категории в том же слое. В этом слое количество нейронов равно количеству выборок.

$$f_A = \sum_{i=1}^m g(z_i) \quad (4)$$

(5) Выходной слой представляет собой конкурентный нейронный решающий слой, где конкурентная функция выбирает максимальную вероятность, которая является конкурентным выходом другой функции плотности вероятности, и каждый нейрон соответствует одной категории соответственно.

Количество нейронов в выходном слое равно количеству обучающих выборок. Обычно данные тестирования близки к данным выборки. В итоге в конкурирующем процессе побеждает только один нейрон. Выход нейрона с максимальной вероятностью равен 1, а категория соответствует положительному результату классификации выборки, а остальные нейроны — отрицательным результатам классификации выборки.

2.2 Метод классификации на основе модели PNN

Модель PNN относится к контролируемому сетевому классификатору, обладает характеристиками быстрого обучения, хорошей отказоустойчивостью и способностью точной классификации. Метод классификации, основанный на модели PNN, можно описать следующим образом:

СВЯЗЬ

Предположим, что есть две категории θ_A, θ_B . Для каждой выборки $X = [x_1, x_2, \dots, x_n]$ она принадлежит θ_A или θ_B . Он должен удовлетворять правилу Байеса:

Если $h_A l_A f_A(X) > h_B l_B f_B(X)$, то $X \in \theta_A$; если $h_A l_A f_A(X) < h_B l_B f_B(X)$, то $X \in \theta_B$;

Где h_A и f_A – априорные вероятности, и они удовлетворяют условию $h_A = N_A/N$, $h_B = N_B/N$. N_A и N_B – количество обучающихся выборок θ_A и θ_B соответственно. N – общее количество обучающихся выборок. l_A и l_B - функции потерь с неправильным решением соответственно. f_A и f_B – функции плотности вероятности категорий θ_A и θ_B соответственно.

PNN – это искусственная нейронная сеть, основанная на статистическом принципе. Он поглощает преимущества радиальной базисной функции и классического принципа оценки функции плотности вероятности. По сравнению с традиционной нейронной сетью с прямой связью она имеет более значительные преимущества в классификации.

3. Эксперименты и результаты

Значительную роль в определении качества образования играет классификация достижений учащихся. Для объективной, справедливой и разумной оценки качества образования очень важно точно и правильно оценивать учащихся в соответствии с их достижениями. Модель PNN имеет характеристики быстрой скорости классификации, высокой точности и стабильных результатов тестирования.

В этой статье мы в основном устанавливаем модель PNN, чтобы выяснить основные факторы, влияющие на успеваемость учащихся. Кроме того, она классифицирует достижения учащихся на основе метода диверсифицированной оценки, чтобы обеспечить руководство для реформы образования. Классификация достижений студентов включает следующие несколько частей, которые представлены на рисунке 4.



Рис. 4. Следующая схема классификации на основе модели PNN

На рисунке 4 достижения студентов в первую очередь приобретаются деканатом. Затем он создает сеть PNN на основе представленного выше метода. После этого он обучает и проверяет достижения студентов. В этом процессе данные обучения и данные тестирования выбираются случайным образом для повышения точности результатов классификации. Наконец, он получает экспериментальные результаты, и результаты анализируются на основе точности и эффективности соответственно.

С помощью мощной характеристики PNN можно получить удовлетворительные результаты классификации. Достижения учащихся в основном включают обычное поведение, домашнюю работу, промежуточный экзамен и выпускной экзамен и др. В частности, обычное поведение включает посещение (20%), просмотр видео MOOK (15%), взаимодействие (10%), обсуждение (15%), ответ (15%), небольшие эксперименты (15%), краткое эссе (10%). На самом деле, обычное поведение может действительно и эффективно отражать состояние обучения учащихся и их способность к обучению.

Кроме того, поскольку диверсифицированный метод оценки может выявить всесторонние способности учащихся, создается диверсифицированная модель руководства по классификации, основанная на достижениях учащихся.

В таблице 1 показано распределение успеваемости учащихся. Эти данные взяты из курса «Аналоговые электронные технологии», который является отличным провинциальным открытым онлайн-курсом.

Таблица 1
Достижения студентов

Номер	Обычное поведение	Домашняя работа	Средний срок	Окончательный	Всего
1	95	85	85	72	77
2	85	85	83	73	76
3	90	80	83	73	76
4	60	60	80	67	67
5	100	90	85	75	80
6	94	95	79	65	72
7	80	70	70	38	49
8	95	85	75	66	72
9	100	96	96	87	90
10	95	79	82	66	72
11	95	75	81	56	64
12	60	60	68	69	67
13	95	85	87	68	74
14	100	94	92	84	87

Разделяет достижения учащихся на пять категорий: отлично, хорошо, средне, удовлетворительно и неудовлетворительно. На самом деле, полезно изучить потенциальные способности учащихся и обеспечить полезное справочное значение для реформы образования путем всесторонней оценки достижений учащихся. Что касается модели PNN, то она содержит множество параметров. Различные параметры оказывают большое влияние на его производительность. Значение спреда – один из важных параметров, от которого зависит точность тестирования. Влияние величины спреда на PNN показано на рисунке 5.

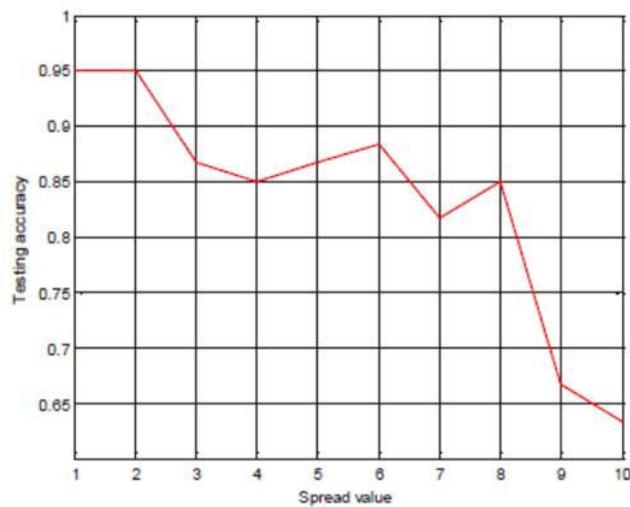


Рис. 5. Влияние величины спреда на PNN

На рисунке 5 видно, что показатель точности тестирования имеет тенденцию к снижению с увеличением значения спреда.

В частности, когда значение разброса установлено на 10, показатель точности тестирования составляет всего 63,33%, что не способствует классификации достижений учащихся. Поэтому важно выбрать разумное значение спреда. В этой статье значение спреда установлено равным 1 на основе приведенного выше анализа.

Достижения учащихся делятся на пять оценок, соответствующих 15 моделям PNN. 15 моделей показаны в таблице 2.

Таблица 2

Соответствующая связь между моделью входными переменными

Оценки	Модель	Обычное поведение	Домашняя работа	Средний срок	Окончательный	Всего
1	1	✓	✓	✓	✓	✓
2	2		✓	✓	✓	✓
3	3			✓	✓	✓
4	4				✓	✓
5	5					✓
6	6		•	•	•	•
7	7			•	•	•
8	8				•	•
9	9					•
10				○	○	○
11					○	○
12						○
13					■	■
14						■
15						❖

Различные модели будут давать разную точность тестирования. Чтобы продемонстрировать способность PNN классифицировать достижения учащихся, модель общей регрессионной нейронной сети (GRNN) также используется для одновременной классификации достижений учащихся, а диаграмма сравнения точности тестирования 15 моделей показана на рисунке 5.

На рисунке 6 можно получить более высокую точность тестирования с использованием модели GRNN, чем у модели PNN во время моделирования с 1 по модель 12. Однако в модели 14 и модели 15 точность тестирования на основе модели PNN выше, чем у GRNN. модель. Кроме того, он может достичь точности тестирования только 93,33% на основе модели GRNN, в то время как самая высокая точность тестирования может достигать 95% на основе модели PNN.

Кроме того, согласно приведенным выше результатам тестирования, мы можем сделать соответствующие предложения по учебной ситуации студентов. Например, как показано в таблице 1, № 2 и № 3 имеют одинаковые общие баллы, но их обычное поведение и домашние задания разные. Таким образом, мы можем выдвинуть конкретные предложения для двух студентов на основе полученных результатов. Кроме того, мы можем выдвинуть некоторые мнения в соответствии с rationalностью классификации студентов, чтобы студенты увидели свои преимущества и недостатки и лучше спланировали свое будущее обучение.

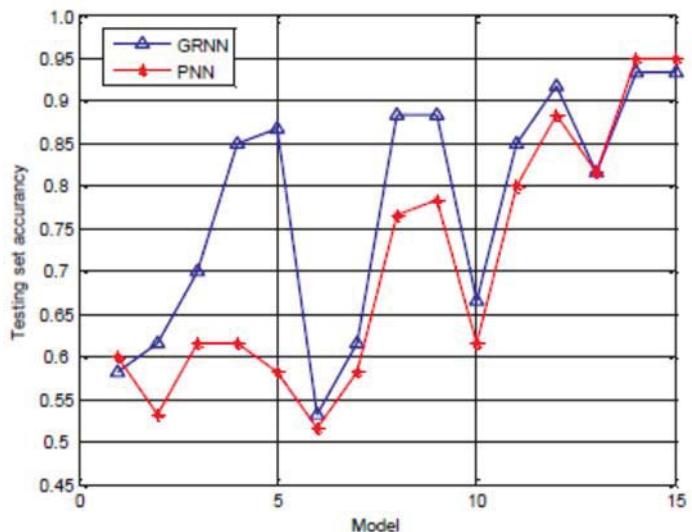


Рис. 6. Диаграмма сравнения точности тестирования на разных моделях

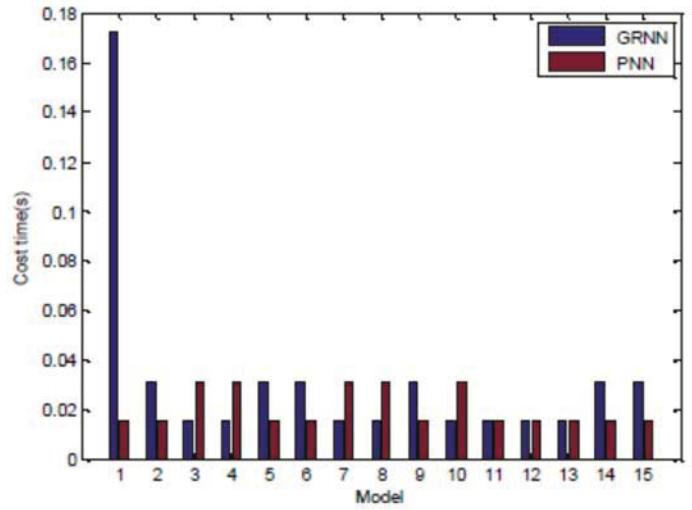


Рис. 7. Диаграмма сравнения стоимости и времени на основе моделей GRNN и PNN

Что касается системы обнаружения, эффективность является еще одним фактором, заслуживающим внимания. Обычно использование другой модели требует разного времени. Как показано на рис. 7, на основе модели GRNN потребуется больше времени, чем на основе модели PNN. Самое длинное время составляет 0,1716 с на основе модели GRNN, в то время как самое длинное время составляет 0,0312 с, а самое короткое время составляет всего 0,0156 с на основе модели PNN. Очевидно, что 14-я и 15-я модели имеют значительные преимущества в эффективности классификации.

В соответствии с точностью и эффективностью классификации мы используем 15-ю модель GRNN и PNN для классификации достижений учащихся соответственно. Результат классификации показан на рисунке 8.

На рисунке 8 представлены 3 категории ошибок во время 60 тестовых выборок на основе модели PNN, а 4 категории ошибок возникают в модели GRNN.

Кроме того, мы классифицируем достижения учащихся с использованием модели PNN, время затрат составляет всего 0,0156 с, а точность классификации составляет 95%, что доказывает, что это эффективный метод определения качества образования, основанный на модели PNN.

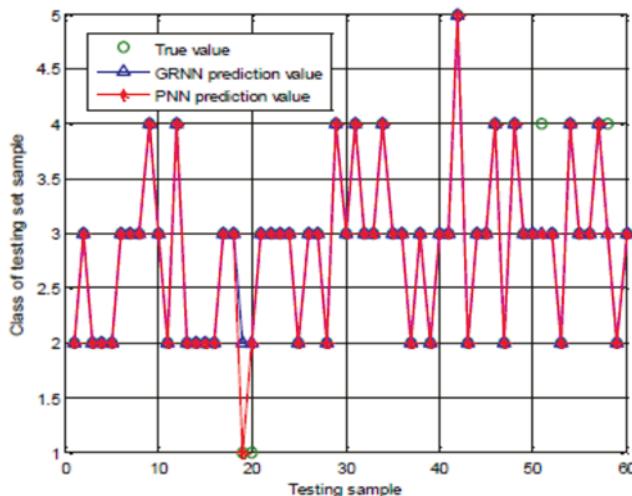


Рис. 8. Классификация выборки тестовой выборки на основе моделей GRNN и PNN

Вывод

Модель PNN включает в себя входной слой, слой шаблона, слой суммирования и выходной слой. Он использует байесовский классификатор и теорию принятия решений для построения модели системы. В этом процессе в качестве функции активации используется нелинейная функция Гаусса. Он обладает преимуществами быстрой скорости и высокой точности классификации, поэтому он подходит для определения качества образования путем классификации достижений учащихся. В этой статье достижения и способности студентов полностью рассматриваются с использованием модели PNN для классификации их достижений. Экспериментальные результаты доказывают, что предложенный метод обладает высокой точностью и эффективностью классификации. Это эффективный и обоснованный метод определения качества образования.

В дальнейшем дальнейшие исследования могут быть проведены со следующих аспектов:

(1) Увеличить разнообразие классов и количество выборок данных.

(2) Увеличить разнообразие индекса оценки качества обучения студентов.

(3) Применить продвинутую теорию глубокого обучения, такую как сверточная нейронная сеть, сеть глубокого убеждения и т. д., для анализа образцов данных и использовать

больше методов для сравнения с предлагаемым методом, чтобы еще больше повысить эффективность определения качества обучения учащихся.

Литература

1. Мухамед Бен Хай Роума, Йовиша Жунич, Мухаммед Чачан Юнис. Инвариантные моменты для многокомпонентных форм с приложениями к классификации листьев // Компьютеры и электроника в сельском хозяйстве. 2017. № 142(А). С. 326-337. <https://doi.org/10.1016/j.compag.2017.08.029>.
2. Фаллата Ахмад, Джонс Саймон, Митчелл Дэвид. Классификация случайных лесов на основе объектов для выявления неформальных поселений на Ближнем Востоке: пример из Джидды // Международный журнал дистанционного зондирования. 2020. № 41(11). С. 4421-4445. <https://doi.org/10.1080/01431161.2020.1718237>
3. Ко Б.К., Гим Дж.В., Нам Дж.Й. Классификация изображений ячеек на основе признаков ансамбля и случайного леса // Электроника Письма. 2011. №47 (11). С. 638-U72. <http://dx.doi.org/10.1049/el.2011.0831>
4. Сара Н., Алями, Сандей О. Олатунджи. Применение машины опорных векторов для классификации арабских настроений с использованием набора данных на основе Twitter // Журнал управления информацией и знаниями. 2020. № 19 (01)2040018. С. 1-13. <https://doi.org/10.1142/S0219649220400183>
5. Арируджанамби Д., Варун Кумар К.А., Сиби Чаккараварти С. и др. Классификация вредоносного трафика с использованием анализа основных компонентов и искусственной нейронной сети для экстремального наблюдения // Компьютерные коммуникации. 2019. №147. С. 50-57. <https://doi.org/10.1016/j.comcom.2019.08.003>.
6. Хамид Ганбари, Саид Хомаюни, Абдолреза Сафари и др. Модель гауссовой смеси и марковские случайные поля для классификации гиперспектральных изображений // Европейский журнал дистанционного зондирования. 2018. № 51(1). С. 889-900. <https://doi.org/10.1080/22797254.2018.1503565>
7. Мирвазири Х., Мобараке З.С. Улучшение классификации изображений движений на основе ЭЭГ с использованием оптимизации роя частиц на основе топологии кольца // Биомедицинская обработка сигналов и контроль. 2017. № (32). С. 69-75. <https://doi.org/10.1016/j.bspc.2016.10.015>
8. Anibou C, Saidi MN, Aboutajdine D. Классификация текстурированных изображений на основе дискретного вейвлет-преобразования и слияния информации // Журнал систем обработки информации. 2015. № 11(3). С. 421-437. <https://doi.org/10.3745/LIPS.02.0028>
9. Синь Р.Ю., Чжан Дж., Шао Ю.Т. Сложная сетевая классификация со сверточной нейронной сетью // Цинхуа Наука и техника. 2020. № 25(4). С. 447-457. <https://dx.doi.org/10.26599/TST.2019.9010055>
10. Грисшабер Д., Ву Н.Т., Маучер Дж. Классификация текста с низким уровнем ресурсов с использованием обучения с состязательной областью // Компьютерная речь и язык. 2020. № 62. С.101056. <https://doi.org/10.1016/j.csl.2019.101056>
11. Чжан Чao, Wan Цзяндун, Хuan Цзянь и др. Обнаружение и классификация коротких замыканий в распределительных сетях на основе подхода Fortescue и регрессии softmax // Международный журнал по электроэнергетике и энергетической системе. 2020. С. 118-105812. <https://doi.org/10.1016/j.ijepes.2019.105812>

USING A PROBABILISTIC NEURAL NETWORK ALGORITHM TO MEASURE THE LEVEL OF EDUCATION QUALITY

Al-Dulaimi Omar Hatem Zaidan, Voronezh State Technical University, Voronezh, Russia, oamar1982@yandex.ru

Abstract

The traditional method of determining the quality of education is too unambiguous and unreasonable, which is not suitable for a comprehensive assessment of students' abilities. The purpose of the article is to justify the use of a probabilistic neural network algorithm. Research methods. The reliability of the presented results is ensured by the analysis of scientific literature, modeling of a probabilistic neural network, comparative analysis of models and evaluation of the effectiveness of the model. Research results. In this paper, a probabilistic neural network (PNN) algorithm is used to determine the quality of education by considering the important influence between different student achievements. The PNN algorithm comes from the Bayesian decision rule and uses the nonlinear Gauss-Parsen window as a probability density function. Since the PNN model has strong nonlinear and anti-interference properties, it is suitable for determining the quality of education by classifying student achievements. In addition, this article also discusses the impact of various evaluation models on the accuracy and effectiveness of classification. In addition, the influence of the spread value on the PNN model is also discussed. Scope of application. Finally, evidence is used to determine the quality of education. Conclusions. Experimental results show that the detection accuracy can reach 95%, and the detection time is only 0.0156 s based on the proposed method. That is, the method is a very practical detection algorithm with high accuracy and efficiency. In addition, it also contains information on how to further improve the quality of teaching. It is proved that the use of the PNN model makes it possible to accurately classify the achievements of students according to the quality criterion.

Keywords: probabilistic neural network; classification; student performance; quality of education.

References

1. Mohamed Ben Hai Rouma, Jovisha Junic, Mohammed Chachan Yunis. Moment invariants for multicomponent forms with applications to leaf classification. *Computers and electronics in agriculture*. 2017, no. 142(A), pp. 326-337. <https://doi.org/10.1016/j.compag.2017.08.029>.
2. Fallata Ahmad, Jones Simon, Mitchell David. Classification of random forests based on objects to identify informal settlements in the Middle East: an example from Jeddah. *International Journal of Remote Sensing*. 2020, no. 41(11), pp. 4421-4445. <https://doi.org/10.1080/01431161.2020.1718237>
3. Ko B.K., Gim J.V., Nam J.Y. Classification of cell images based on ensemble features and random forest. *Electronic Letters*. 2011, no. 47(11), pp. 638-U72. <http://dx.doi.org/10.1049/el.2011.0831>
4. Sara N., Alami, Sunday O. Olatunji. Application of a support vector machine to classify Arab sentiments using a Twitter-based dataset. *Journal of Information and Knowledge Management*. 2020, no. 19 (01)2040018, pp. 1-13. <https://doi.org/10.1142/S0219649220400183>
5. Arivudainambi D., Varun Kumar K.A., Sibi Chakkaravarti S. et al. Classification of malicious traffic using the analysis of the main components and an artificial neural network for extreme surveillance. *Computer communications*. 2019, no. (147), pp. 50-57. <https://doi.org/10.1016/j.comcom.2019.08.003>
6. Hamid Ghanbari, Said Khomayuni, Abdolreza Safari. and others. Gaussian mixture model and Markov random fields for classification of hyperspectral images. *European Journal of Remote Sensing*. 2018, no. 51(1), pp.: 889-900. <https://doi.org/10.1080/22797254.2018.1503565>
7. Mirvaziri H., Mobarake Z.S. Improving the classification of motion images based on EEG using particle swarm optimization based on ring topology. *Biomedical signal processing and control*. 2017, no. (32), pp. 69-75. <https://doi.org/10.1016/j.bspc.2016.10.015>
8. Anibou C, Saidi MN, Aboutajdine D. Classification of textured images based on discrete wavelet transformation and information fusion. *Journal of information processing systems*. 2015, no. 11(3), pp. 421-437. <https://doi.org/10.3745/JIPS.02.0028>
9. Xin R.Yu., Zhang J., Shao Y.T. Complex network classification with convolutional neural network. *Tsinghua Science and Technology*. 2020, no. 25(4), pp. 447-457. <https://dx.doi.org/10.26599/TST.2019.9010055>
10. Grisshaber D., Wu N.T., Moucher J. Classification of low-resource text using adversarial domain learning. *Computer speech and language*. 2020, no. 62, p.101056. <https://doi.org/10.1016/j.csl.2019.101056>
11. Zhang Chao, Wang Jiangdong, Huang Jian, etc. Detection and classification of short circuits in distribution networks based on the Fortescue approach and softmax regression. *International Journal of Electric Power and Energy System*. 2020, pp. 118-105812. <https://doi.org/10.1016/j.ijepes.2019.105812>