

ОБУЧЕНИЕ МОДЕЛИ НА ОСНОВЕ АДАПТИВНОЙ НЕЙРО-НЕЧЕТКОЙ СИСТЕМЫ ВЫВОДА ДЛЯ ОЦЕНКИ РИСКА

А.А. Болгов

Работа посвящена анализу производительности модели для оценки риска на основе адаптивной нейро-нечеткой системы вывода. Подробно рассмотрен алгоритм обучения адаптивной нейро-нечеткой системы вывода. Проведено несколько экспериментов в среде MATLAB для оценки эффективности предложенного метода нечеткой оценки риска. Рассмотрено ограниченное количество эпох для каждого эксперимента. Для сравнения проводимых экспериментов, обучение системы проводилось гибридным методом и методом обратного распространения. При проведении экспериментов были использованы восемь основных функций принадлежности. В результате проведенных экспериментов получены оценки основных параметров, связанных с ошибками обучения и проверки системы. Проведено сравнение полученных результатов для всех заданных исходных параметров. Выявлена зависимость изменения величины ошибки от количества эпох. Приведены результаты обучения модели на основе адаптивной нейро-нечеткой системы вывода при различном количестве эпох.

Ключевые слова: нейро-нечеткая система, интернет вещей, функция принадлежности, метод обучения, риск, ошибка обучения, ошибка проверки, эпоха.

Введение

Быстродействие большинства методов машинного обучения увеличивается в результате обучения. В этой статье рассматривается обучение модели на основе адаптивной нейро-нечеткой системы вывода (АННСВ). Процесс обучения начинается с разделения набора данных на обучающий и контрольный. Обучающий набор данных представляет собой множество входных и выходных векторов. Они необходимы для обучения системы АННСВ. Обучающий набор данных используется для поиска начальных параметров необходимых для функций принадлежности. Пороговое значение для ошибки между наблюдаемым и прогнозируемым результатом должно быть равным 0.05 [1, 2]. Последующие параметры определяются с использованием метода наименьших квадратов. Если полученная ошибка превышает пороговое значение, то параметры предпосылки обновляются при помощи метода градиентного спуска. Процесс завершается, когда ошибка становится меньше порогового значения. Затем при помощи контрольного набора данных проводится проверка фактических данных с вывода адаптивной нейро-нечеткой системы [3].

Модель предложенной методики оценки риска на основе АННСВ была обучена с использованием, как гибридного метода обучения, так и метода обратного распространения. В процессе обучения были использованы восемь функций принадлежности для выбора наиболее подходящего метода обучения, а также выбора лучшей функции принадлежности для реализации процесса оценки риска в рамках предлагаемой методики, основанной на риске. К этим восьми ФП относятся: треугольная ФП (TriMF), трапециевидная ФП (TrapMF), обобщенная колоколообразная ФП (GbellMF), гауссова ФП (GaussMF), двойная гауссова ФП (Gauss2MF), пи-образная ФП (PiMF), двойная сигмоидная ФП (DsigMF) и произведение двух сигмоидных ФП (PsigMF).

На рис. 1 показан процесс обучения модели на основе АННСВ. Первым шагом является подготовка обучающих данных для работы с адаптивной нейро-нечеткой системой вывода в MATLAB. Набор данных, используемый в качестве входных для функции *anfis*, должен представлять собой матрицу, где последний столбец этой матрицы включает в себя выходные данные, а сама матрица содержит столько столбцов, сколько необходимо для представления входных данных системы. Строки

представляют все существующие комбинации данных. Перед началом процесса обучения был использован графический интерфейс fuzzy logic toolbox в MATLAB для определения типа функций принадлежности для нечетких множеств. Затем АННСВ была обучена с использованием восьми ФП для выбора наилучшей из них с наименьшей ошибкой. После завершения процесса обучения, были зафиксированы итоговые функции принадлежности, а также ошибки обучения из обучающего набора данных.

После этого, проверочный набор данных использовался в сочетании с обучающим набором данных для повышения производительности [3]. После завершения процесса проверки, обученный нечеткий интерфейс системы (НИС) используется для оценки производительности системы. После завершения обучения будут оценены характеристики нейро-нечеткой системы вывода для определения наиболее подходящих нечетких параметров с наименьшей ошибкой.

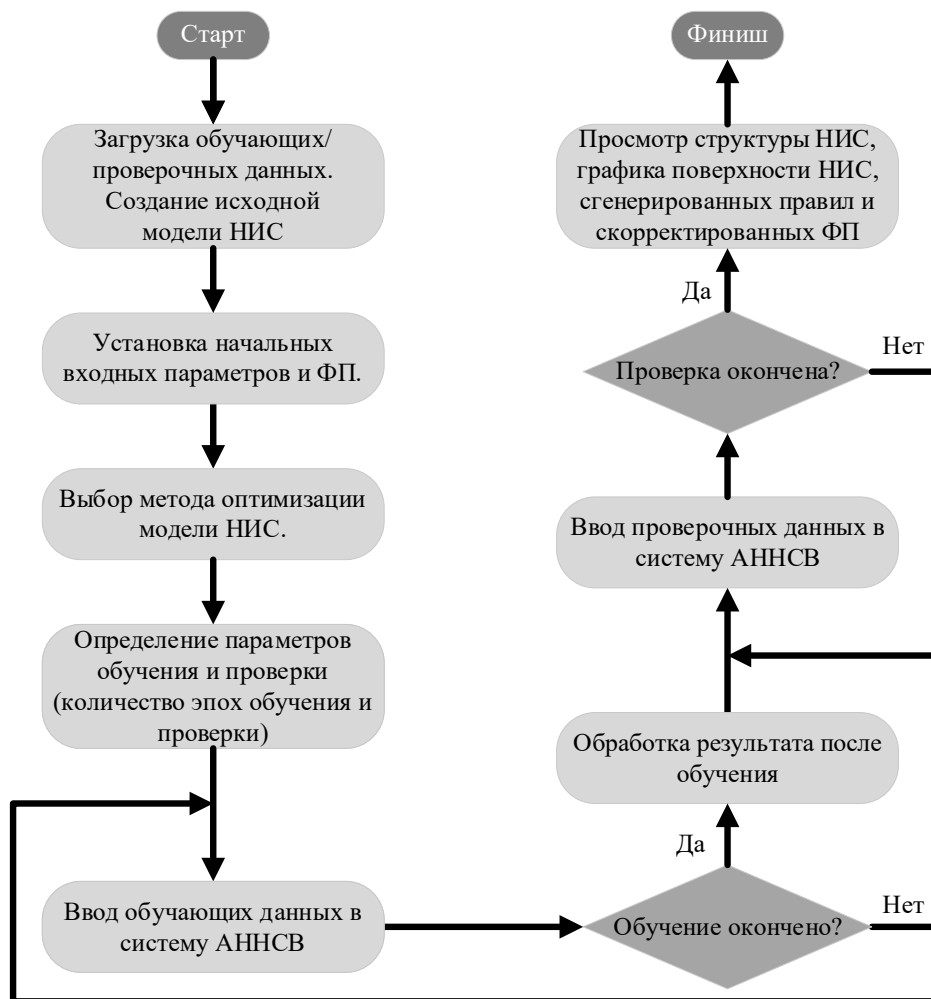


Рис. 1. Процесс обучения модели на основе АННСВ

Обученный НИС каждой функции принадлежности был использован для получения прогнозируемого результата. Затем прогнозируемый результат сравнивался с наблюдаемым результатом для вычисления ошибки с использованием MAE и RMSE, а также определения наилучшего соответствия процессу обучения с помощью R и R^2 . Было проведено несколько

экспериментов для обучения АННСВ и оценки производительности обученных НИС.

Во время обучения адаптивной нейро-нечеткой системы вывода может возникнуть одна из распространенных проблем – переобучение. Это происходит, когда данные перетренированы. Как правило, каждый обученный набор данных имеет максимально возможное количество эпох до момента возникновения переобучения. Переобучение

приводит к тому, что вероятность ошибки обученной модели обучающими данными оказывается существенно выше, чем средняя ошибка самих этих данных [1, 4, 5]. Следовательно, каждый набор данных должен быть обучен с использованием оптимального количества эпох, которое может быть определено путем проведения многочисленных экспериментов. Переобучение анализируется путем построения графика ошибки обучения и проверки при моделировании нейро-нечеткой системы вывода. Чтобы избежать проблемы переобучения, АННСВ следует обучать при разном количестве эпох.

Результаты обучения

Все эксперименты проводились с использованием двух отдельных наборов данных: обучающего и контрольного. Обучающий набор данных был использован для обучения модели на основе АННСВ, в то время как контрольный набор данных использовался для проверки обученной модели. Чтобы получить наименьшую ошибку и наилучшим образом обучить модель на основе АННСВ, ее обучение производилось при трех эпохах: 20, 100 и 300.

Обучение при 20 эпохах

Оптимальная настройка модели на основе АННСВ зависит от выбранных функций принадлежности, метода обучения и количества эпох для каждого обучения. Было проведено несколько экспериментов по обучению модели на основе АННСВ с использованием как гибридных, так и обратных алгоритмов обучения. Эти эксперименты проводились при 20 эпохах с восьмью функциями принадлежности, чтобы выбрать более подходящую из них, при которой будет наименьшая ошибка и которая наилучшим образом будет соответствовать процессу обучения.

После того, как модель на основе АННСВ была обучена, для проверки ее производительности и точности был использован весь набор данных. Значения RMSE, MAE использовались для определения величины ошибки между прогнозируемыми значениями и полученными из обученной модели на основе АННСВ. А величины R и R² были использованы для демонстрации соответствия модели и ее процесса обучения. Результаты обучения модели на основе АННСВ при 20 эпохах приведены в табл. 1.

Таблица 1

Оценка эффективности модели на основе АННСВ при 20 эпохах

Алгоритм обучения	Функции принадлежности	Ошибка обучения	Ошибка проверки	Оценка эффективности			
				RMSE	MAE	R	R ²
Гибридный	TriMF	5.361	5.413	5.389	4.244	0.974	0.939
	TrapMF	4.664	4.765	4.675	3.571	0.983	0.957
	GbellMF	5.173	5.186	5.251	4.088	0.976	0.943
	GaussMF	5.215	5.244	5.211	4.021	0.977	0.944
	Gauss2MF	4.671	4.681	4.691	3.582	0.983	0.957
	PiMF	4.854	4.863	4.878	3.722	0.981	0.952
	DsigMF	4.711	4.717	4.728	3.608	0.982	0.956
	PsigMF	4.712	4.718	4.728	3.609	0.982	0.956
Обратное распространение ошибки	TriMF	51.554	51.555	51.544	48.258	0.842	-5.490
	TrapMF	51.347	51.334	51.329	48.119	0.736	-5.437
	GbellMF	52.043	52.041	52.031	48.642	0.880	-5.613
	GaussMF	51.711	51.701	51.699	48.370	0.881	-5.529
	Gauss2MF	51.353	51.343	51.337	48.118	0.748	-5.438
	PiMF	51.334	51.319	51.316	48.110	0.721	-5.433
	DsigMF	51.345	51.334	51.328	48.109	0.744	-5.436
	PsigMF	51.345	51.334	51.328	48.109	0.744	-5.436

При использовании гибридного метода обучения ошибки обучения и проверки были очень малы для всех восьми функций принадлежности. Комбинация алгоритмов обратного распространения и градиентного спуска в гибридном методе обучения продемонстрировала, что ошибка принимает наименьшее значение только после 20 эпох. Кроме того, результаты эксперимента показали, что для четырех функций принадлежности, включая TrarMF, PiMF, DsigMF и Gauss2MF, ошибки обучения и

проверки в течение всех 20 эпох не изменялись. На рис. 2 показаны ошибки обучения и проверки при использовании TrarMF с гибридным методом обучения при 20 эпохах. На нем видно, что при увеличении количества эпох никаких улучшений не происходит. В то время как другие четыре функции принадлежности, включая TriMF, GbellMF, PiMF и GaussMF, показывают небольшое снижение ошибок обучения и проверки при увеличении количества эпох с 1 до 20 (рис. 3).

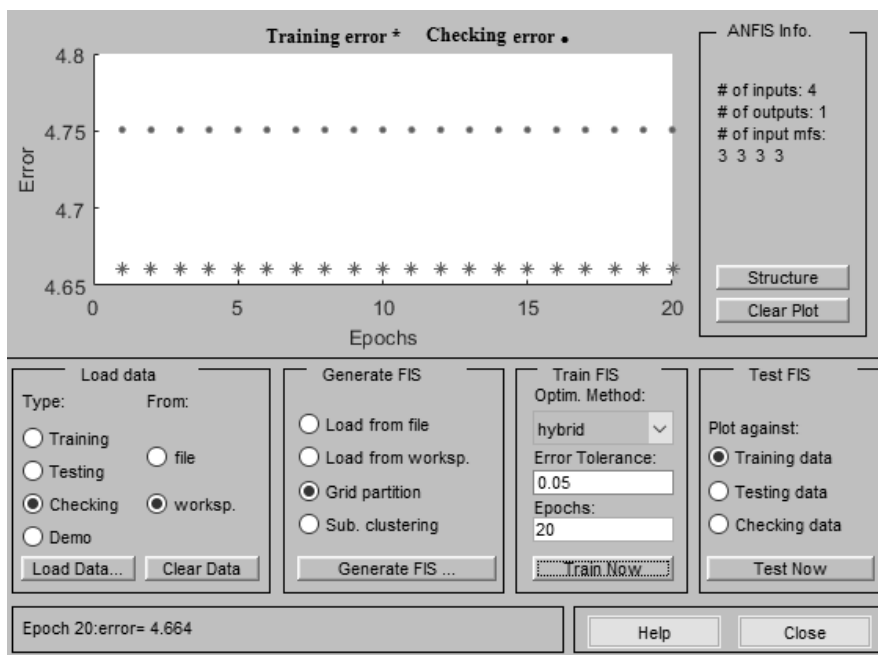


Рис. 2. Ошибка обучения и проверки при использовании TrarMF с гибридным методом обучением при 20 эпохах




Рис. 3. График зависимости ошибки RMSE обучения при использовании TriMF с гибридным методом обучения от количества эпох

При этом, из всех восьми функций принадлежности можно выделить TranMF , при которой достигается наименьшее значения ошибок RMSE и MAE среди остальных. Данная ФП наилучшим образом соответствует процессу обучения со значениями R и R^2 , равными 0.974 и 0.939 соответственно. На рис. 4 показан график регрессии всего набора данных,

используемого для оценки производительности модели с функцией принадлежности TranMF при гибридном методе обучения. Этот график показывает, что прогнозируемые значения очень близки к идеальной прямой, а, следовательно, предложенная модель на основе АННСВ с выбранной функцией принадлежности хорошо подходит.

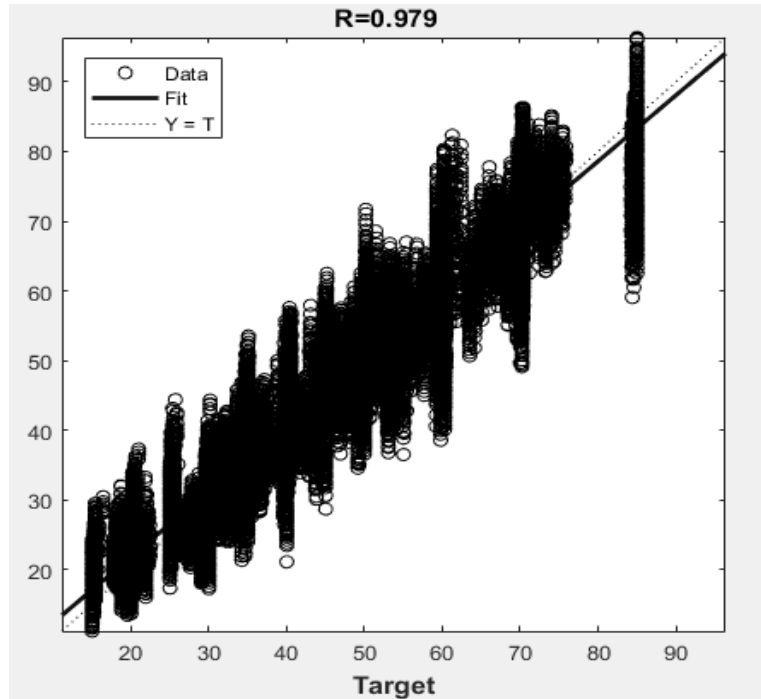


Рис. 4. График регрессии всего набора данных при использовании TranMF с гибридным методом обучения

Также для обучения модели на основе АННСВ при 20 эпохах был использован метод с обратным распространением. Результаты показали, что данный метод обучения привел к значительному снижению как ошибок обучения, так и ошибок проверки для всех восьми функций принадлежности. Но при этом метод обучения с обратным распространением приводит к большим значениям ошибок RMSE и MAE , но малым значениям R и R^2 . Это, в свою очередь, показывает тот факт, что взаимосвязь между прогнозируемыми и наблюдаемыми данными менее эффективна и требует дополнительной подготовки. Кроме того, значения R^2 получились отрицательными, что подразумевает наличие обратной

зависимости между прогнозируемыми и наблюдаемыми данными. Это может привести к тому, что увеличение прогнозируемых данных приведет к уменьшению наблюдаемых данных. Важным аспектом, наблюдаемым при использовании метода обучения с обратным распространением при 20 эпохах, является то, что ошибки обучения и проверки были значительно уменьшены при увеличении количества эпох для всех восьми функций принадлежности. На рис. 5 показано резкое уменьшение ошибок RMSE как при обучении, так и при проверке для TranMF с методом обучения обратного распространения через 20 эпох. Данный результат показывает, что переобучения нет.




Рис. 5. График зависимости ошибки RMSE обучения от количества эпох при использовании TrarMF с методом обучения обратного распространения

После обучения модели на основе АННСВ при 20 эпохах было выявлено, что увеличение количества эпох оказывает незначительное влияние на ошибки обучения и проверки при использовании гибридного метода обучения. При этом если использовать метод обучения обратным распространением, то ошибки обучения и проверки будут снижаться с увеличением количества эпох. Однако, функция принадлежности TrarMF в совокупности с гибридным методом обучения является оптимальной из восьми выбранных ФП, так как при ее использовании величина ошибки принимает минимальное значение. Соответственно выбранная функция TrarMF принадлежности наилучшим образом соответствует процессу обучения.

Обучение при 100 эпохах

Определение наилучших настроек в предлагаемой модели на основе АННСВ для ее обучения и получения наивысшей точности зависит от выбранных функций принадлежности, метода обучения и количества эпох для каждого обучения. После того, как модель была обучена при 20 эпохах, была выполнено ее же обучение при 100 эпохах для того, чтобы определить изменится ли производительность модели от

увеличения количества эпох. Увеличение количества эпох для обучения модели в этом эксперименте связано с тем, что обучение при 20 эпохах оказало незначительное влияние на уменьшение ошибок обучения и проверки модели, реализованной с помощью гибридного метода обучения и значительное уменьшение ошибок обучения и проверки с помощью метода обучения обратным распространением. Таким образом, увеличение количества эпох может привести к большему количеству улучшений, особенно при использовании метода обучения с обратным распространением. Следовательно, цель этого эксперимента состоит в том, чтобы обучить модель при 100 эпохах и убедиться в том, что будет достигнуто наилучшее соответствие процессу обучения и наименьшее значение ошибок.

Было проведено несколько экспериментов при 100 эпохах с восьмью функциями принадлежности, чтобы определить наилучшую из них, которая дает наименьшую величину ошибки и наилучшим образом соответствует процессу обучения с использованием как гибридного, так и обратного методов обучения. Ошибки обучения и проверки, а также показатели оценки производительности, полученные в результате обучения, приведены в табл. 2.

Оценка эффективности модели на основе АННСВ при 100 эпохах

Алгоритм обучения	Функции принадлежности	Ошибка обучения	Ошибка проверки	Оценка эффективности			
				RMSE	MAE	R	R ²
Гибридный	TriMF	5.357	5.410	5.385	4.242	0.974	0.939
	TrapMF	4.654	4.665	4.675	3.571	0.984	0.958
	GbellMF	5.119	5.140	5.147	3.986	0.977	0.946
	GaussMF	5.203	5.230	5.232	4.073	0.976	0.943
	Gauss2MF	4.671	4.681	4.691	3.582	0.983	0.959
	PiMF	4.849	4.857	4.872	3.717	0.981	0.952
	DsigMF	4.706	4.717	4.729	3.608	0.983	0.956
	PsigMF	4.707	4.716	4.729	3.609	0.983	0.956
Обратное распространение ошибки	TriMF	29.583	29.601	29.596	27.201	0.854	-1.146
	TrapMF	29.488	29.480	29.474	26.782	0.796	-1.128
	GbellMF	31.356	31.361	31.357	28.903	0.887	-1.408
	GaussMF	30.068	30.074	30.072	27.758	0.888	-1.215
	Gauss2MF	29.404	29.410	29.395	26.721	0.799	-1.117
	PiMF	29.561	29.546	29.539	26.783	0.789	-1.138
	DsigMF	28.396	28.398	28.389	25.534	0.786	-0.976
	PsigMF	28.395	28.397	28.388	25.533	0.786	-0.975

Результаты эксперимента показали, что поведение модели на основе АННСВ при 100 эпохах было аналогичным поведению при 20 эпохах. Для гибридного метода обучения ошибки обучения и проверки показали очень незначительное снижение по сравнению со значениями ошибок, полученными при 20 эпохах. Другими словами, группа функций принадлежности, включающая в себя TrapMF, Gauss2MF, DsigMF, PsigMF, не показала никаких различий в ошибках обучения и проверки, а также в показателях оценки производительности при увеличении количества эпох с 20 до 100. В то время как другая группа функций принадлежности, включая TriMF, GbellMF, GaussMF и PiMF, показала очень небольшое снижение ошибок обучения и проверки при увеличении количества эпох до 100. На рис. 6 показаны ошибки обучения и проверки при использовании функции принадлежности GbellMF с гибридным методом обучения при 100 эпохах. Данный эксперимент показал небольшое снижение ошибок обучения и проверки при увеличении количества эпох.

Также стоит отметить использование функции принадлежности TrapMF, которая, в свою очередь, не показала никаких улучшений при увеличении числа эпох до 100, но при этом данная функция

принадлежности является наилучшей среди восьми выбранных, так как она обеспечивает самые низкие значения ошибок RMSE и MAE среди других и наилучшим образом соответствует процессу обучения со значениями R и R², равными 0.984 и 0.958 соответственно.

Для метода обучения с обратным распространением увеличение числа эпох до 100 продемонстрировало резкое снижение ошибок обучения и проверки для всех функций принадлежности. Ошибка обучения уменьшилась с 51.3 до 28.3 при 100 как для DsigMF, так и для PsigMF. На рис. 7 показаны ошибки обучения и проверки через 100 эпох при использовании функции принадлежности TriMF совместно с методом обучения обратного распространения. Данный результат показывает, что переобучения нет, поскольку обучающие и проверочные значения ведут себя одинаково.

Таким образом, можно сделать вывод о том, что после увеличение количества эпох до 100, обучение модели гибридным методом привело к небольшому уменьшению ошибок обучения и проверки. Однако, при использовании метода обучения обратного распространения, оказывает значительное влияние на уменьшение ошибок обучения и проверки. При этом функция

принадлежности TrapMF с гибридным подходом к обучению по-прежнему является оптимальной функцией принадлежности, которая выдает наименьшую ошибку и наилучшим образом соответствует процессу обучения.

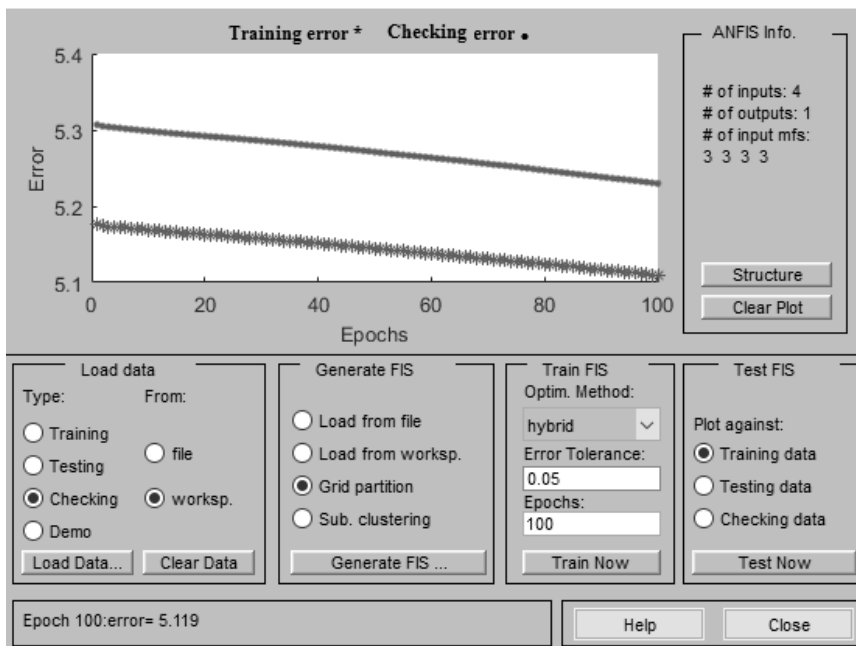


Рис. 6. Ошибка обучения и проверки при использовании GbellMF с гибридным методом обучением при 100 эпохах

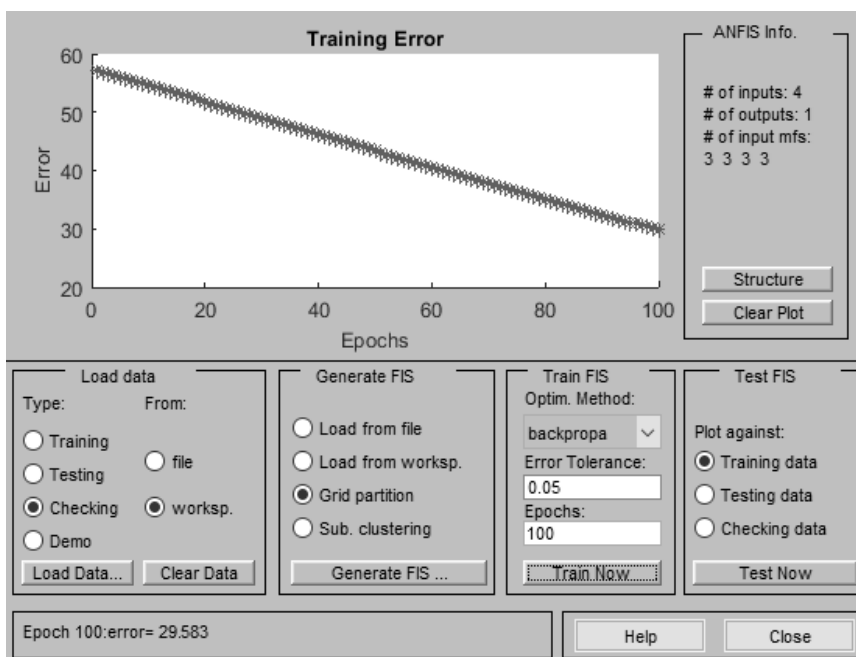


Рис. 7. Ошибка обучения при использовании TrifM с методом обучения обратного распространения при 100 эпохах

Обучение при 300 эпохах

Анализируя результаты предыдущих экспериментов, можно сделать вывод о том, что обучение модели на основе АННСВ с помощью гибридного метода дает адекватные результаты. Но при этом было выявлено, что модель нуждается в

дополнительной подготовке с использованием метода обучения обратного распространения. Поэтому, был проведен дополнительный эксперимент обучения модели при 300 эпохах, чтобы выяснить изменится ли производительность модели от увеличения количества эпох. Было проведено

несколько экспериментов при 300 эпохах с функциями принадлежности при использовании как гибридного, так и обратного методов обучения, чтобы определить наилучшую функцию

принадлежности, которая дает наименьшую величину ошибки и наилучшим образом соответствует процессу обучения. Результаты обучения модели на основе АННСВ при 300 эпохах отражены в табл. 3.

Таблица 3

Оценка эффективности модели на основе АННСВ при 300 эпохах

Алгоритм обучения	Функции принадлежности	Ошибка обучения	Ошибка проверки	Оценка эффективности			
				RMSE	MAE	R	R ²
Гибридный	TriMF	5.349	5.402	5.376	4.238	0.974	0.940
	TrapMF	4.654	4.665	4.675	3.5714	0.984	0.958
	GbellMF	4.999	5.015	5.023	3.880	0.979	0.949
	GaussMF	5.149	5.181	5.178	4.019	0.977	0.945
	Gauss2MF	4.671	4.681	4.691	3.582	0.983	0.957
	PiMF	4.839	4.846	4.862	3.709	0.981	0.953
	DsigMF	4.707	4.717	4.728	3.608	0.982	0.956
	PsigMF	4.708	4.716	4.728	3.609	0.982	0.956
Обратное распространение ошибки	TriMF	6.318	6.375	6.350	5.040	0.959	0.911
	TrapMF	5.919	5.955	5.946	4.635	0.966	0.924
	GbellMF	6.301	6.359	6.339	5.002	0.960	0.912
	GaussMF	6.421	6.474	6.459	5.108	0.959	0.908
	Gauss2MF	5.871	5.908	5.898	4.587	0.967	0.925
	PiMF	6.041	6.076	6.070	4.737	0.964	0.920
	DsigMF	9.935	10.023	9.960	7.884	0.905	0.768
	PsigMF	7.548	7.599	7.570	6.016	0.942	0.870

Результаты эксперимента показали, что поведение модели на основе АННСВ при 300 эпохах было аналогичным поведению при 20 и 100 эпохах. При гибридном методе обучения ошибки обучения и проверки показали очень незначительное снижение по сравнению со значениями ошибок, полученными при 20 или 100 эпохах. Другими словами, группа функций принадлежности, включающая TrapMF, Gauss2MF, DsigMF, PsigMF, не показала никаких различий в ошибках обучения и проверки, а также в показателях оценки производительности при увеличении количества эпох.

Глядя на табл. 3, можно сделать вывод о том, что при увеличении количества эпох до 300 для группы функций принадлежности TriMF, GbellMF, GaussMF и PiMF, результатом стало небольшое снижение ошибок обучения и проверки. На рис. 8

показаны ошибки обучения и проверки при использовании GbellMF совместно с гибридным методом обучения при 300 эпохах. При увеличении количества эпох заметно небольшое снижение ошибок обучения и проверки. Также на рисунке заметно, что примерно через 275 эпох уменьшение ошибок прекратилось, а это означает, что нет необходимости в дополнительном обучении, поскольку увеличение количества эпох не приведет к каким-либо изменениям. Стоит отметить, что переобучение также не произошло. Результаты данного эксперимента показали, что функция принадлежности TrapMF по-прежнему является лучшей функцией принадлежности, которая обеспечивает наименьшие ошибки RMSE и MAE среди других и наилучшим образом соответствует процессу обучения со величинами R и R², равными 0.984 и 0.958 соответственно.

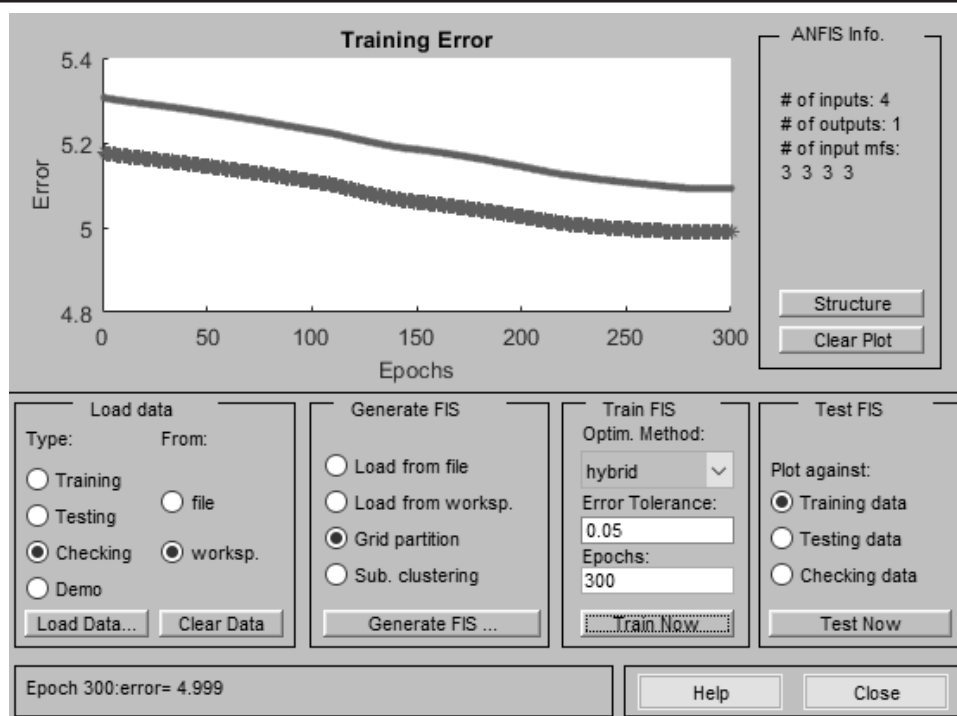


Рис. 8. Ошибка обучения при использовании GbellMF с гибридным методом обучением при 300 эпохах

Для метода обучения обратным распространением увеличение числа эпох до 300 продемонстрировало резкое снижение ошибок обучения и проверки для всех функций принадлежности. При увеличении числа эпох ошибка обучения при использовании функции принадлежности Gauss2MF уменьшилась с 29.4 до 5.8. На рис. 9 показаны ошибки обучения и проверки

в эксперименте с использованием функции принадлежности TriMF в совокупности с методом обучения обратного распространения для 300 эпох. Данный эксперимент показал, что примерно через 280 эпох уменьшение ошибок почти прекратилось, а это означает, что нет необходимости в дополнительном обучении.




Рис. 9. Графики зависимости ошибки обучения и проверки от количества эпох при использовании TriMF с методом обучения обратного распространения

Оценка эффективности метода обучения с обратным распространением при 300 эпохах показала разные результаты. Использование функций принадлежности TriMF и Gauss2MF выдало наименьшие ошибки RMSE и MAE, а также самые высокие значения R и R². При этом модель с функцией принадлежности DsigMF выдала самые высокие ошибки RMSE и MAE и самые низкие значения R и R². Также стоит отметить, что подход к обучению с обратным распространением показал резкое снижение ошибок обучения и проверки при увеличении числа эпох. Но при этом он достигает своей наименьшей ошибки (5.87) примерно через 280 эпох, в то время как подход с гибридным обучением достигает своего наименьшего значения ошибки (4.65) после первой эпохи при использовании функции принадлежности TrapMF.

Сравнение методов обучения при разных эпохах

Модель на основе АННСВ предлагаемого метода оценки риска была обучена с использованием как гибридных, так и обратных методов обучения при трех разных эпохах: 20, 100 и 300. Это было сделано для того, чтобы исследовать скорость обучения модели на основе адаптивной нейро-нечеткой системы вывода в разные эпохи и определить наилучшую функцию принадлежности, которая дает наименьшую

ошибку и наилучшим образом соответствует процессу обучения.

Результаты гибридного метода обучения при 20, 100 и 300 эпох продемонстрировали, что группа функций принадлежности, включающая TrapMF, Gauss2MF, DsigMF и PsigMF, не показала никаких изменений в ошибках RMSE, MAE, а также значениях R и R² при увеличении количества эпох с 1 до 300 (табл. 4). В то время как другая группа функций принадлежности, включающая TriMF, GbellMF, GaussMF и PiMF, показала незначительное снижение значений ошибок RMSE и MAE и очень небольшое увеличение значений R и R² при увеличении количества эпох. Например, значение RMSE TriMF уменьшается с 5.389 до 5.385 при увеличении количества эпох с 20 до 100 и затем уменьшается до 5.376 при увеличении количества эпох до 300. Аналогичное поведение сохранялось для всей этой группы, за исключением GaussMF, которая показала другое поведение, в котором значение RMSE увеличилось с 5.211 до 5.232 при увеличении числа эпох с 20 до 100, но потом снова уменьшилось до 5.178 при увеличении числа эпох до 300. При этом модель с использованием функции принадлежности GbellMF показала наибольшее уменьшение ошибок среди других функций принадлежности, в которой значение RMSE уменьшилось с 5.251 при 20 эпохах до 5.023 при 300 эпохах.

Таблица 4

Оценка эффективности модели на основе АННСВ с использованием гибридного метода обучения при разных эпохах

Функции принадлежности	При 20 эпохах				При 100 эпохах				При 300 эпохах			
	RMSE	MAE	R	R ²	RMSE	MAE	R	R ²	RMSE	MAE	R	R ²
TriMF	5.389	4.244	0.974	0.939	5.385	4.242	0.974	0.939	5.376	4.238	0.974	0.940
TrapMF	4.675	3.571	0.983	0.957	4.675	3.571	0.984	0.958	4.675	3.571	0.984	0.958
GbellMF	5.251	4.088	0.976	0.943	5.147	3.986	0.977	0.946	5.023	3.880	0.979	0.949
GaussMF	5.211	4.021	0.977	0.944	5.232	4.073	0.976	0.943	5.178	4.019	0.977	0.945
Gauss2MF	4.691	3.582	0.983	0.957	4.691	3.582	0.983	0.959	4.691	3.582	0.983	0.957
PiMF	4.878	3.722	0.981	0.952	4.872	3.717	0.981	0.952	4.862	3.709	0.981	0.953
DsigMF	4.728	3.608	0.982	0.956	4.729	3.608	0.983	0.956	4.728	3.608	0.982	0.956
PsigMF	4.728	3.609	0.982	0.956	4.729	3.609	0.983	0.956	4.728	3.609	0.982	0.956

Результаты метода обучения с обратным распространением при 20, 100 и 300 эпохах продемонстрировали, что все функции принадлежности показали значительное снижение значений RMSE и MAE и значительное увеличение значений R и R² при

увеличении количества эпох, как показано в табл. 5. Например, значение RMSE для функции принадлежности TriMF уменьшилось с 51.544 до 29.596 при увеличении количества эпох с 20 до 100 и дополнительно уменьшилось до 6.35 при

увеличении количества эпох до 300. Значения R^2 имели отрицательный знак при 20 и 100 эпохах, что подразумевает наличие обратной зависимости между прогнозируемыми и наблюдаемыми данными. Отрицательное число исчезло при увеличении количества эпох до 300. После применения метода обучения с обратным распространением с различным количеством эпох было выявлено, что Gauss2MF более подходящей функцией принадлежности, поскольку при ее использовании были получены самые низкие значения RMSE (5.898) и MAE (4.587) и самые высокие значения R (0.967) и R^2 (0.925).

По завершению проведения экспериментов можно сделать вывод о том, что увеличение количества эпох оказало значительное влияние на функции принадлежности при использовании метода обучения с обратным распространением, в котором процесс обучения занял около 280 эпох, чтобы достичь самых низких значений RMSE и MAE. Хотя значения ошибок RMSE функций принадлежности с методом обучения обратного распространения значительно уменьшались при увеличении числа эпох, но оно не смогло достичь наименьшего значения ошибки, полученного с помощью гибридного метода обучения после первой эпохи.

Таблица 5

Оценка эффективности модели на основе АННСВ с использованием метода обучения на основе обратного распространением при разных эпохах

Функции принадлежности	При 20 эпохах				При 100 эпохах				При 300 эпохах			
	RMSE	MAE	R	R^2	RMSE	MAE	R	R^2	RMSE	MAE	R	R^2
TriMF	51.544	48.258	0.842	-5.490	29.596	27.201	0.854	-1.146	6.350	5.040	0.959	0.911
TrapMF	51.329	48.119	0.736	-5.437	29.474	26.782	0.796	-1.128	5.946	4.635	0.966	0.924
GbellMF	52.031	48.642	0.880	-5.613	31.357	28.903	0.887	-1.408	6.339	5.002	0.960	0.912
GaussMF	51.699	48.370	0.881	-5.529	30.072	27.758	0.888	-1.215	6.459	5.108	0.959	0.908
Gauss2MF	51.337	48.118	0.748	-5.438	29.395	26.721	0.799	-1.117	5.898	4.587	0.967	0.925
PiMF	51.316	48.110	0.721	-5.433	29.539	26.783	0.789	-1.138	6.070	4.737	0.964	0.920
DsigMF	51.328	48.109	0.744	-5.436	28.389	25.534	0.786	-0.976	9.960	7.884	0.905	0.768
PsigMF	51.328	48.109	0.744	-5.436	28.388	25.533	0.786	-0.975	7.570	6.016	0.942	0.870

Изучение результатов с использованием гибридного метода и с обратным распространением показывает, что функция принадлежности TrapMF с гибридным методом обучения при 20 эпохах является оптимальной комбинацией для реализации модели на основе АННСВ предлагаемого метода оценки риска. Данная комбинация дала самые низкие значения RMSE, MAE, а также самые высокие значения R и R^2 среди всех других функция принадлежности при различном количестве эпох после первой эпохи, как показано на рис. 10. Она наилучшим образом соответствовал процессу обучения с корреляцией 0.984. Это говорит о том, что прогнозируемые значения очень близки к идеальной линейной прямой и предложенная модель на основе адаптивной нейро-нечеткой системы вывода хорошо обучена.

Заключение

Для анализа производительности модели на основе адаптивной нейро-нечеткой системы вывода для оценки риска было подробно рассмотрено ее обучение при использовании различных функций принадлежности. В результате проделанной работы для настройки выбранных функций принадлежности было проведено несколько экспериментов. Они включали в себя использование двух отдельных наборов данных: обучающего и контрольного. В качестве метода обучения модели были выбраны: гибридный метод и метод обратного распространения. А для того, чтобы выбрать наилучшую функцию принадлежности для модели, ее обучение проводилось при 20, 100 и 300 эпохах. Результаты оценки ошибок обучения и проверки показали, что функция принадлежности TrapMF с гибридным

методом обучения при 20 эпохах является оптимальной комбинацией для реализации модели на основе нейро-нечеткой системы вывода для оценки риска. Данная комбинация уже после первой эпохи достигла наименьшей ошибки обучения и проверки, которые остаются такими же с увеличением количества эпох. А поскольку эта

комбинация дала самые низкие значения оценки RMSE и MAE, то она наилучшим образом соответствует процессу обучения с корреляцией 0.9731. Полученный результат говорит о том, что выбранная модель на основе нейро-нечеткой системы вывода является хорошо обученной.

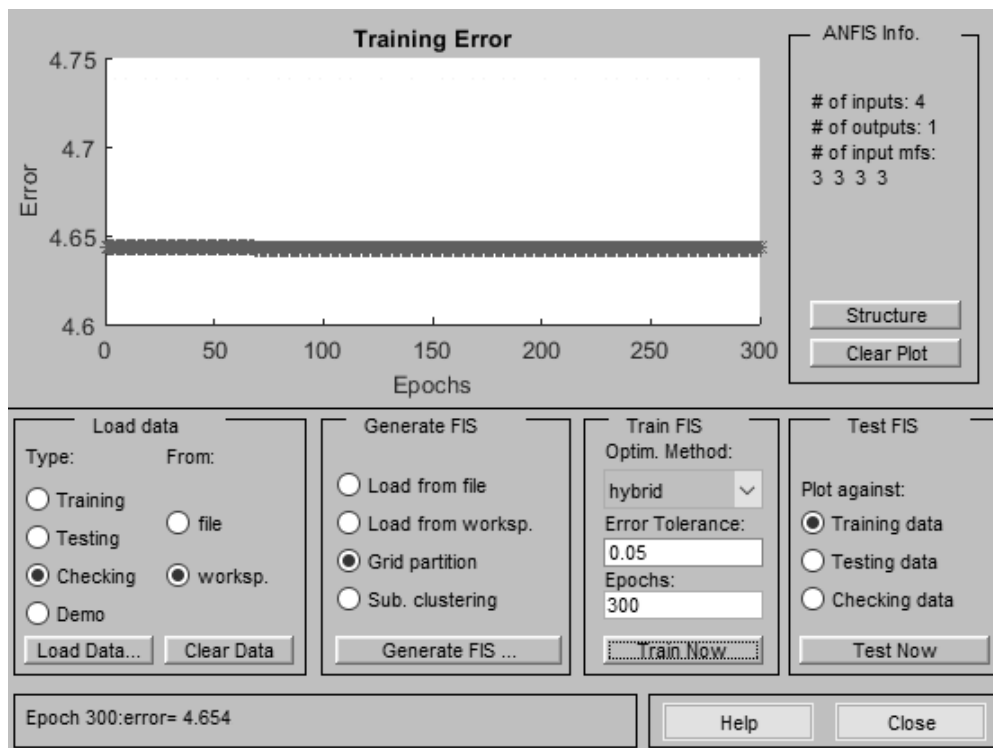


Рис. 10. Ошибка обучения при использовании TrarMF с гибридным методом обучения при 300 эпохах.

Список литературы

1. Al-Hmouz, A., Jun Shen, Al-Hmouz, R., Jun Yan. Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning. IEEE Transactions on Learning Technologies, 2012, no. 5(3), pp. 226–237.
2. Jing Q., Vasilakos A. V., Wan J., Lu J., Qiu D. Security of the internet of things: Perspectives and challenges. Wireless Networks, 2014, no. 20(8), pp. 2481–2501.
3. Jang, J. S. R. ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE

- Transactions on Systems, Man and Cybernetics, 1993, no. 23(3), pp. 665–685.
4. IT and management of information risks// [Электронный ресурс] Режим доступа: http://www.it.ru/press_center/publications/3818
5. Kotenko I., Saenko I., Skorik F., Bushuev S. Neural network approach to forecast the state of the Internet of Things elements. Proc. of XVIII Int. Conf. on Soft Computing and Measurements (SCM). St. Petersburg, 2015, pp. 133–135.

Воронежский государственный технический университет
Voronezh State Technical University

Поступила в редакцию 11.11.2022

Информация об авторе

Болгов Андрей Александрович – аспирант, Воронежский государственный технический университет, e-mail: mnac@comch.ru

**MODEL TRAINING BASED ON ADAPTIVE NEURO-FUZZY
INFERENCE SYSTEM FOR RISK ASSESSMENT**

A.A. Bolgov

The work is devoted to the analysis of the model performance based on an adaptive neuro-fuzzy inference system for risk assessment. The algorithm of training an adaptive neuro-fuzzy inference system is considered in detail. Several experiments were conducted in the MATLAB environment to evaluate the effectiveness of the proposed method of fuzzy risk assessment. A limited number of epochs for each experiment is considered. To compare the experiments conducted, the system was trained using a hybrid method and a back propagation method. During the experiments, eight basic membership functions were used. As a result of the experiments, estimates of the main parameters associated with errors in training and system verification were obtained. A comparison of the results obtained for all the given initial parameters is carried out. The dependence of the error change on the number of epochs is revealed. The results of training a model based on an adaptive neuro-fuzzy inference system for a different number of epochs are presented.

Keywords: neuro-fuzzy system, internet of things, membership function, training method, risk, training error, checking error, epoch.

Submitted 11.11.2022

Information about the author

Andrey A. Bolgov – graduate student, Voronezh State Technical University, e-mail: mnac@comch.ru