

Методика оценки экономической надежности ИТ предприятия на основе нейронных сетей

А.В. КЛИМЕНКО¹, М.В. ЯЦКОВЕЦ¹, Ю.С. КАРАСЬ²

В статье рассматривается актуальность повышения экономической надежности ИТ предприятия. Предлагается подход к повышению экономической надежности используя ИНС, которая основана на объединении байесовской структуры и метода усреднения модели в единую структуру.

Ключевые слова: экономическая надежность, методы оценки надежности, устойчивость, категория устойчивости.

The relevance of improving the economic reliability of an IT enterprise is considered. An approach to improving economic reliability using ANN is proposed, which is based on combining the Bayesian structure and the averaging method of the model into a single structure.

Keywords: economic reliability, methods of assessing reliability, sustainability, sustainability category.

Введение. В настоящее время численные модели все чаще используются для анализа и прогнозирования производительности сложных критических систем. В то же время практикующие инженеры обеспокоены неопределенностью, которая присуща этим системам. Как следствие, в последние десятилетия большое внимание уделяется вероятностному анализу, такому как анализ экономической надежности и оптимизация надежности. Однако вычислительные затраты, необходимые для выполнения вышеупомянутых анализов, зависят от нескольких факторов, таких как: численная модель, представляющая систему, тип анализа и обработка неопределенностей (т. е. алеаторная и/или эпистемическая неопределенность) [1, с. 113]. В контексте анализа экономической надежности распространение неопределенностей параметров от входов модели к выходам осуществляется с помощью подходов, основанных на моделировании методом Монте-Карло. Эти подходы моделирования включают в себя: Монте-Карло (МК) [2, с. 85] и продвинутое МК, такие как: выборка важности, направленная выборка, линейная выборка, моделирование подмножеств и т. д. Хотя передовые методы МК очень эффективны, вычислительные затраты, необходимые для выполнения анализа экономической надежности ИТ предприятия, являются дорогостоящими. Популярной стратегией снижения вычислительных затрат является замена реальной модели суррогатной моделью, такой как искусственная нейронная сеть (ИНС). ИНС может быть построена на основе нескольких наборов данных из базовой интересующей модели. С другой стороны, использование ИНС приводит к возникновению неопределенности при выборе модели, а также к отклонениям в оценке экономической надежности ИТ предприятия. На самом деле, ИНС с определенной архитектурой, многократно обученная конечному набору данных $D_i(x, y)$ приводит к различным исполняющим ИНС, функции затрат которых захватываются в разных локальных минимумах пространства решений функций затрат. Это явление возникает в результате случайной инициализации весов внутри каждой ИНС. Следовательно, общепринятой практикой является выбор наилучшей ИНС из неопределенного набора на основе производительности на независимом наборе валидации и сохранение только сети с наименьшей ошибкой валидации и отбрасывание остальных. Однако у такого подхода есть два недостатка. Во-первых, все усилия, необходимые для обучения остальных сетей, тратятся впустую. Во-вторых, производительность обобщения сетей на проверочном наборе имеет случайную составляющую из-за шума на данных, поэтому сеть, которая имела самую низкую ошибку на проверочном наборе, может плохо работать на новом тестовом наборе. Эти недостатки можно преодолеть, объединив сети вместе, чтобы позволит значительно повысить надежность прогнозируемой величины. Таким образом, в данной работе предложен подход к повышению экономической

надежности ИТ предприятия на основе нейронной сети используя для прогнозирования вероятности отказа p_F . Рассматривается теория анализа надежности с использованием имитационного подхода и нейросетевого моделирования для повышения надежности.

Определение проблемы. Анализ экономической надежности. Функция предельного состояния может быть просто определена как детерминированное отображение из z -мерного входного пространства в одномерное выходное пространство:

$$G: x \in D_x \supset R_z \rightarrow y = G(x) \in R,$$

где x – z -мерные переменные состояния, а y – переменная производительности. $G(x)$ указывает, соответствует ли реализация $x \in D_x$ безопасному состоянию ($G(x) > 0$) или состоянию отказа ($G(x) \leq 0$). В контексте теории вероятностей, вероятность отказа p_F определяется как вероятность того, что реализация $x \in D_x$ соответствует состоянию отказа в терминах функции предельного состояния $G(x)$

$$p_F = P(G(x) \leq 0) = \int_{D_f} f_x(x) dx,$$

где $D_f = \{x \in D_x : G(x) \leq 0\}$ – область отказа, а $f_x(x)$ – функция плотности вероятности состояния переменных X . Поскольку уравнение аналитически неразрешимо в силу своей многомерности, моделирование методом Монте-Карло позволяет численно вычислить оценку вероятности отказа p_F учетом большой выборки размера N :

$$\hat{p}_F = \frac{1}{N} \sum_{i=1}^N I_{G(x) \leq 0}(x_i),$$

где $I_{G(x) \leq 0}$ – индикаторная функция отказа, такая что $I = 1$ для $G(x) \leq 0$ $I = 0$ в противном случае.

Моделирование искусственной нейронной сети для оценки экономической надежности ИТ предприятия. Недостатком использования моделирования методом Монте-Карло для вычисления оценки p_F является большое количество оценок модели, необходимых для вычисления оценки экономической надежности ИТ предприятия. Следовательно, вместо предельной функции состояния можно использовать ИНС для снижения вычислительных затрат. Для построения ИНС требуется набор реальных пар входных/выходных данных $D_i(x, y)$ размера N_i , генерируемых в соответствии с моделью сигнал плюс шум $y = \mu(x) + \varepsilon$, где y – наблюдаемая производительность, генерируемая из модели, x – независимые переменные состояния, отобранные из плотности вероятности $\Omega(x)$ ε – независимый, идентично распределенный шум, отобранный из плотности $\Psi(\varepsilon)$ (не обязательно гауссовой), имеющей среднее значение 0 и дисперсию σ^2 и $\mu(x)$ – неизвестная функция, которая должна быть аппроксимирована путем нахождения аппроксимации $\hat{\mu}(x)$ из $D_i(x, y)$. Можно сделать первые предположения о функциональной форме $\mu(x)$. Однако, поскольку класс параметрических функций обычно неизвестен, необходимо прибегнуть к непараметрическому регрессионному подходу. Используя непараметрический подход, можно построить оценку $\hat{\mu}(x)$ из большого класса функций Υ , которые, как известно, обладают хорошими аппроксимационными свойствами. Класс аппроксимационных функций обычно содержит набор оценок $f(w, x) \in \Upsilon$, для которых элементы каждого подкласса $f(w, x)$ непрерывно параметризуются набором p весов w^α ; $\alpha = 1, 2, \dots, p$. Алгоритм градиентной декомпозиции, который используется для минимизации функции стоимости J нейронной сети, определяется как:

$$J = \frac{1}{N_t} \sum_{i=1}^{N_t} (y_i - \hat{y}_i)^2,$$

найдя набор весов w^a такой, что для любого заданного входного сигнала функция затрат достаточно мала. Однако ограничением градиентного алгоритма обучения ИНС является возможность того, что функция затрат будет захвачена локальным минимумом, тем самым снижая прогностическую способность сети.

Предлагаемый подход. Данный подход направлен на повышение надежности прогноза экономической надежности ИТ предприятия при использовании ИНС. Основная идея предлагаемого подхода заключается в построении набора ИНС с одинаковой архитектурой и на основе одного и того же набора обучающих данных $D_t(x, y)$. Таким образом, создается распределение идентичных ИНС, имеющих свои функции ошибок, захваченные в различных локальных минимумах. Основной идеей этого подхода является то, что пространство решений функции ошибки эксплуатируется как можно больше раз с возможностью нахождения глобальных минимумов на поверхности ошибки. Далее используется теорема Байеса для оценки апостериорной вероятности каждой из обученных ИНС, на основе вероятности можно предсказать обучающие данные. За этим следует использование метода усреднения модели (подход корректирующего фактора [3, с. 3]) для объединения общего прогноза, сделанного всеми ИНС в наборе, чтобы получить надежный прогноз, сходящийся к истинному значению. Наконец, неопределенность модели, распространяющаяся на прогнозируемую величину, количественно определяется в терминах доверительных интервалов.

Выбор модели Байеса для построения нейронной сети. Учитывая множество M идентичных (т. е. одну и ту же структуру модели) конкурирующих ИНС $N_k, k=1, 2, \dots, M$, обученных с одним и тем же набором данных $D_t(x, y)$, теорема Байеса может быть использована для выражения апостериорной вероятности k -й ИНС в множестве, которое определяется:

$$P(N_k | D_t) = \frac{P(D_t(x, y) | N_k) P(N_k)}{\sum_{q=1}^M P(D_t(x, y) | N_q) P(N_q)},$$

где $P(D_t(x, y) | N_k)$ – вероятность обучающих данных $D_t(x, y)$ для N_k ИНС, а $P(N_k)$ – априорная вероятность N_k , которая представляет собой вероятность ИНС, оцененную перед наблюдением обучающих данных $D_t(x, y)$. Априорная вероятность ИНС может быть задана в зависимости от существующих априорных знаний о достоверности ИНС N_k , или она может быть задана как равномерная вероятность, $P(N_k) = 1/M$, если дополнительная информация не предоставляется. Преимущество присвоения равномерной априорной вероятности состоит в том, что избегается трудность численной оценки априорной вероятности. Вероятность $P(D_t(x, y) | N_k)$ можно рассматривать как вероятность наблюдения обучающих данных. Это обеспечивает относительную меру того, насколько хорошо ИНС поддерживается обучающими данными. Поскольку знаменатель в уравнении является общим для всех ИНС, то апостериорная вероятность ИНС пропорциональна априорной вероятности. Вероятность каждой ИНС оценивается путем измерения степени согласия между обучающими данными и ответом \hat{y} для каждой ИНС. Следовательно, можно описать вероятностную связь между обучающими данными и предсказаниями ИНС, включающими неопределенность. Как правило, функция смещения и шум включаются как части вероятностной зависимости для сопоставления прогнозов ИНС с обучающими данными. Функция смещения фиксирует расхождения между ответами дорогостоящей модели и прогнозами, сделанными ИНС. Шум обычно считается независимой и тождественно распределенной нормальной случайной величиной со средним значением, равным нулю [1, с. 231].

Прогноз искусственной нейронной сети. Чтобы получить прогноз экономической надежности ИТ предприятия от ИНС, оценки, сделанные всеми последующими обученными

ИНС, объединяются с использованием метода усреднения модели. В частности, подход корректирующего фактора [3, с. 5], представляющий собой метод усреднения модели, сочетается с теоремой Байеса. Таким образом, ИНС, имеющая наибольшую апостериорную вероятность, используется в сочетании с другими соответствующими ИНС, обученными корректировать оценку смещения, предсказанную единственной ИНС. Корректирующий коэффициент A_f оценивается путем предположения, что ошибка между предсказанием всех последующих обученных ИНС и обучающими данными распределена нормально. Предсказание надежности ИНС может быть получено из следующего уравнения:

$$y_{над.} = \hat{y}^* + A_f,$$

где \hat{y}^* представляет собой точечную оценку наилучшего ИНС в множестве, характеризующемся наибольшей вероятностью, а $y_{над.}$ представляет собой предсказание экономической надежности ИТ предприятия, включающее неопределенность модели. Поскольку корректирующий фактор A_f предполагается нормальным распределением, ожидаемое значение и дисперсия корректирующего фактора A_f задаются следующими соотношениями:

$$E(A_f) = \sum_{k=1}^M P(N_k | D_t) (\hat{y}_k - \hat{y}^*).$$

Аналогично, ожидаемое значение и дисперсия прогноза экономической надежности $y_{над.}$ могут быть оценены из следующих соотношений:

$$E(y_{над.}) = \hat{y}^* + E(A_f),$$

где $E(A_f)$ $Var(A_f)$ представляют ожидаемое значение и дисперсию корректирующего коэффициента, а $E(y_{над.})$ $Var(y_{над.})$ представляют ожидаемое значение и дисперсию оценки экономической надежности ИТ предприятия.

Доверительный интервал для оценки экономической надежности. Для количественной оценки неопределенности в прогнозировании экономической надежности ИТ предприятия $y_{над.}$ из-за неопределенности модели устанавливаются доверительные интервалы. В частности, 5-й и 95-й процент прогноза надежности используются для количественной оценки неопределенности модели. Теоретически этот интервал, вероятно, содержит истинное оценочное значение. Поскольку предполагается, что неопределенность модели следует нормальному распределению, доверительные интервалы вычисляются из следующих уравнений [4, с. 247]:

$$\overline{CI} = E(y_{над.}) + z^* \sqrt{Var(y_{над.})},$$

где \overline{CI} и \underline{CI} представляют верхний и нижний доверительные интервалы робастной оценки, а z^* – верхнее критическое значение гауссовского распределения, количественно определяющего неопределенность модели.

Закключение. Анализ надежности сложных моделей с использованием имитационного подхода является вычислительно дорогостоящим из-за большого количества оценок моделей, необходимых для вычисления экономической надежности ИТ предприятия. В этой статье ИНС используется в качестве замены дорогостоящей модели для облегчения вычислительных ограничений. Использование ИНС для такого рода анализа вносит дополнительные смещения и дисперсии (то есть неопределенности) в прогнозируемую величину. Использование метода перекрестной валидации для выбора наилучшей ИНС из набора ИНС с идентичной архитектурой вводит смещение и снижает надежность прогнозируемой величины. Поэтому был представлен новый подход для повышения точности прогноза (т. е. надежности), сделанного ИНС, и количественной оценки неопределенностей модели в терминах доверительных интервалов. Предложенный подход объединяет байесовский метод выбора модели и метод усреднения модели в единую структуру. Хотя вычислительные усилия, необходимые для реализации предлагаемого подхода, являются дорогостоящими, стратегии распараллеливания могут быть приняты для уменьшения этих усилий.

Литература

1. Грязнова, А. Г. Экономическая теория : учеб. пособие / А. Г. Грязнова, В. М. Соколинский. – М. : Кнорус, 2014. – 464 с.
2. Соболев, И. М. Метод Монте-Карло / И. М. Соболев. – М. : Наука-Москва, 2012. – 191 с.
3. Nilsen, T. Models and model uncertainty in the context of risk analysis / T. Nilsen, T. Aven. – Norway : Stavanger University College, 2003. – 10 p.
4. Wonnacott, T. H. Introductory statistics / T. H. Wonnacott, R. J. Wonnacott. – New York : Wiley, 1990. – 736 p.

¹Гомельский государственный
университет им. Ф. Скорины

²Белорусский государственный университет
информатики и радиоэлектроники

Поступила в редакцию 15.04.2021

РЕПОЗИТОРИЙ ГГУ ИМЕНИ Ф. СКОРИНЫ