

ПРОГНОЗИРОВАНИЕ ОБЪЁМОВ ПРОДАЖ АВТОМОБИЛЬНЫХ АККУМУЛЯТОРНЫХ БАТАРЕЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

С.В. Шабунин

аспирант, e-mail: AgranomMotor@yandex.ru

Омский государственный технический университет, Омск, Россия

Аннотация. Рассмотрены вопросы прогнозирования объёмов продаж автомобильных аккумуляторных батарей торговой организации с использованием искусственной нейронной сети. Определены значимые параметры для построения прогноза объёмов продаж автомобильных аккумуляторных батарей с требуемой точностью.

Ключевые слова: искусственная нейронная сеть, прогнозирование, объём продаж автомобильных аккумуляторных батарей.

Введение

В настоящее время совершенствование систем, способствующих улучшению эффективности товародвижения на предприятии оптовой торговли, является важным элементом стратегии ведения бизнеса. В современной экономической среде структурные изменения спроса, товарные эмбарго, ограничительные санкции и многие другие факторы, эффективные методы моделирования и прогнозирования товарных остатков и объёмов продаж дают оптовым организациям необходимое преимущество. Построение прогноза, которое учитывает влияние параметров, таких как температура окружающей среды, скорости ветра, относительной влажности воздуха, влияет на планирование бизнеса: анализ продаж, формирование оптимальных запасов, построение бизнес-плана, планирование бюджета, оптимизацию и контроль расходов, распределение ресурсов компании для обеспечения ожидаемых продаж [1–8]. В прогнозировании объёмов продаж широко используются статистические методы, такие как ARIMA (AutoRegressive Integrated Moving Average) [9] и экспоненциальное сглаживание [10], использование средних для прогнозирования будущих значений временного ряда. Также востребованными являются методы, основанные на интеллектуальном прогнозировании, такие как искусственные нейронные сети (ИНС), используют наименьшее количество данных и времени для обучения, менее подвержены переобучению.

В работе рассмотрено влияние метеоданных на модель при прогнозировании объёмов продаж автомобильных аккумуляторных батарей, определяя значимые технологические параметры.

1. Формирование массива исходных данных

В исследовании используются данные, полученные от торговой фирмы «Николь», крупнейшего поставщика автомобильных аккумуляторных батарей в Сибирском федеральном округе, и представленные массивом, состоящим из объёмов продаж аккумуляторных батарей (Омская обл.) за период с 01.09.2021 по 01.12.2023. Фрагмент исходных данных представлен в табл. 1.

Таблица 1. Исходные данные объёмов продаж автомобильных аккумуляторных батарей

Момент времени	Технологические параметры				
	$V_{руб}$, руб.	$V_{шт}$, шт.	T_A	V_W	ϕ
01.07.2023	415 219,40	114,00	34	1	98
02.07.2023	82 309,81	35,00	25	12	95
03.07.2023	196 068,63	49,00	28	6	94
04.07.2023	209 155,92	54,00	29	5	94
05.07.2023	88 259,44	23,00	23	10	90
06.07.2023	29 530,00	4,00	20	4	90
...		
01.12.2023	1520000	359	-25	15	89

Примечание: $V_{руб}$ – объёмы продаж автомобильных аккумуляторных батарей в денежном выражении, руб. и $V_{шт}$ – объёмы продаж автомобильных аккумуляторных батарей в количественном выражении, шт. Также в таблицу входят метеоданные: T_A – среднесуточная температура окружающей среды; V_W – скорость ветра, м/с; ϕ – относительная влажность воздуха, %.

Для определения структуры, обеспечивающей требуемую точность прогнозирования, сформировано два варианта обучающей выборки. В первом варианте используются все метеоданные в исходном наборе данных (вариант В1). Во втором случае выбираются параметры, имеющие наибольший коэффициент корреляции с объёмом продаж автомобильных аккумуляторных батарей (вариант В2). Для оценки функционирования модели в качестве критерия рассматривалась ошибка прогнозирования объёма продаж автомобильных аккумуляторных батарей. При выполнении исследования рассмотрена модель прогнозирования на основе метода искусственной нейронной сети, который является одним из немногочисленных методов, не требующих предварительной обработки данных. Автоматически обрабатывает категориальные переменные (обозначаемые не числами, а условными символами) и дополняет пропущенные значения, что упрощает его применение.

Для полученных вариантов обучающей выборки производился анализ вклада каждого входного параметра в значение прогноза с целью сокращения количества

входных параметров в модель.

2. Определение вклада входных параметров в значение прогноза

Для определения важности вклада каждого из входных параметров применялся метод SHAP (SHapley Additive exPlanations) [11], который позволяет оценить вероятностный вклад каждого параметра в результат прогноза. Этот метод вычисляет важность конкретного параметра путём сравнения результатов, полученных с учётом этого параметра и без его учёта. Вклад каждого параметра определяется с помощью SHAP значений, вычисляемых по формуле:

$$S_i(x) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N| - |S| - 1)!}{|N|!} [f(x_S \cup \{i\}) - f(x_S)], \quad (1)$$

где $S_i(x)$ – SHAP-значений для i -го параметра и наблюдения x ; N – множество параметров, $|N|$ — его размер; S — подмножество параметров, исключая i -й параметр; $|S|$ — размер подмножества S ; x_S — наблюдение x с учётом только параметров из множества S ; $f(x_S \cup \{i\})$ — прогноз модели для наблюдения x_S , включая i -й параметр; $f(x_S)$ — прогноз для наблюдения x_S . В основе понятия SHAP-значений заложена идея распределения каждого вклада в прогнозирование между всеми вариантами сочетания параметров. Происходит учёт всех возможных перестановок признаков, определяющих, насколько изменяется предсказание при добавлении или удалении отдельных параметров. Каждому параметру присваивается его SHAP-значение, которое показывает, насколько он внёс вклад в прогнозируемое значение.

Для определения структуры обучающей выборки и определения значимости каждого параметра построены графики для двух вариантов структуры входных данных (рис. 1). Графики созданы на основе обработки исходных данных B1 и B2.




Рис. 1. Диаграммы вероятностных вкладов для вариантов прогнозирования: левый – B₁, правый – B₂

На рис. 1. диаграммы показывают силу влияния параметров на прогноз: чёрный указывает на сильное влияние. Значимость параметра определяется его очередно-

стью (сверху вниз): чем выше находится параметр, тем больше его значения воздействуют на итоговый прогноз. Степень влияния на увеличение или уменьшение прогнозных значений определяется по оси абсцисс: чем больше параметр распределяется по оси абсцисс, тем больше он склонен к увеличению или уменьшению прогнозных значений. Таким образом, на графиках отображены наиболее значимые по воздействию параметры вне зависимости от размера обучающей выборки, такими параметрами являются $V_{руб}$, T_A , V_W . Получено, что наибольшее распределение (по оси абсцисс) имеет $V_{руб}$ (значение объёма продаж автомобильных аккумуляторных батарей), определяющий сильную зависимость прогноза от значений $V_{руб}$.

С использованием метода SHAP получены интерпретируемые значения вклада каждого признака в конкретный прогноз модели. При этом входные параметры сравнивались между собой для определения значимости для конечного результата и определения их вклада в прогнозные значения. Те параметры, значимость которых высока, должны быть использованы для построения прогноза в обязательном порядке. Параметры, вносящие наименьший вклад, могут не рассматриваться, если не предъявляются высокие требования к точности прогноза. Отсутствие менее значимых параметров (в случае трудности сбора данных) позволяет сделать прогноз, но точность прогноза ухудшится.

По итогу метода анализа SHAP для рассматриваемых вариантов выявлены значимые параметры (в порядке убывания): $V_{руб}$ – объём продаж автомобильных аккумуляторных батарей, T_A — среднесуточная температура окружающей среды, V_W — скорость ветра, ϕ — относительная влажность воздуха – которые требуют обязательного присутствия в обучающей выборке для прогнозирования объёма продаж автомобильных аккумуляторных батарей.

3. Описание нейросетевой модели для прогнозирования объёмов продаж

При прогнозировании объёмов продаж особое значение имеет метеорологический прогноз погоды, так как нормальная температура работы автомобильных аккумуляторных батарей находится в диапазоне от +20 до –20 °С. Поэтому при повышении температуры окружающей среды электрохимическая активность аккумулятора возрастает, происходит перегрев, что приводит к осыпанию активной массы с пластин аккумуляторных батарей, а также к кипению воды. При понижении температуры ёмкость и пусковой ток аккумуляторных батарей снижается, что затрудняет запуск автомобиля и приводит к потере плотности электролита и последующему замерзанию аккумуляторных батарей. Следует отметить, эксплуатация в таких условиях сокращает срок службы и может привести к выходу из строя аккумуляторной батареи, вследствие чего потребуются её замена, что прямым образом влияет на объём продаж данной продукции.

Для построения нейросетевой модели прогнозирования воспользуемся информационно-аналитической системой Rapidminer с блоками deep learning [12], где функциональные блоки выделены в специальные операторы, с помощью которых формируется обработка данных. Архитектура интеллектуальной нейронной сети формируется с учётом особенностей, влияющих на объём продаж

автомобильных аккумуляторных батарей. Примем, что сеть содержит большое количество скрытых слоёв, состоящих из нейронов с функциями активации \tanh , выпрямителя и \max out. Расширенные функции, такие как адаптивная скорость обучения, скоростной отжиг, тренировка по импульсу, отсев и регуляризация, обеспечивают высокую точность прогнозирования. Каждый вычислительный узел обучает копию параметров глобальной модели на своих локальных данных с помощью многопоточности (асинхронно) и периодически вносит свой вклад в глобальную модель посредством усреднения модели по сети [11]. Структура искусственной нейронной сети (ИНС) имеет 4 слоя, 2 из которых – скрытые. Вход ИНС содержит 4 нейрона. Модель в скрытых слоях содержит 16 нейронов. Выходной слой состоит из 1 нейрона. При прогнозировании с использованием такой структуры модели переобучение не происходит.

Внешние входные данные подаются на входы входного слоя X_1, X_2, \dots, X_n , а W_1, W_2, \dots, W_n – весовые коэффициенты. Сначала нейрон вычисляет взвешенную сумму, далее, применяя функцию активации $F(S)$, вычисляет выходной сигнал Y . Функция активации нейрона – это функция, которая вычисляет выходной сигнал нейрона. На вход этой функции подаётся сумма всех произведений сигналов и весов этих сигналов, и в процессе функционирования нейронная сеть формирует выходной сигнал Y .

Сначала нейрон вычисляет взвешенную сумму (1), далее, применяя функцию активации $F(S)$ вычисляются выходные данные.

$$S = \sum_l W_l X_l - b, \quad (2)$$

где X_l – входной сигнал, W_l – весовые коэффициенты, b – порог нейрона.

$$Y = F(S), \quad (3)$$

где Y – выходные данные, $F(S)$ – функция активации.

Структурная схема приведена на рис. 2.

4. Результаты прогнозирования объёма продаж автомобильных аккумуляторных батарей

Для оценки качества работы и производительности сформированной ИНС применялись метрики, характеризующие точность модели [3]. Значения метрик качества модели от различных структур входных данных и объёмов обучающей выборки представлены в табл. 2.

Используя набор данных В1 с полными технологическими параметрами, модель продемонстрировала лучшие результаты прогнозирования, как указано в табл. 2. Метрика RMSE показала небольшую разницу между фактическими и прогнозируемыми значениями (406915 руб. в лучшем варианте В1), и коэффициент детерминации $R^2 = 0.993$, что говорит о хорошем соответствии модели фактическим данным (99.3 %). Метрика MAPE также подтвердила качество прогноза средней абсолютной процентной ошибкой в 1.93 %.

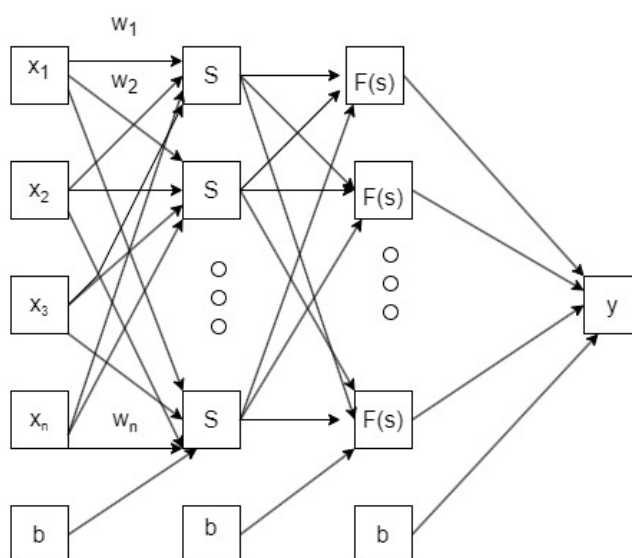


Рис. 2. Структурная схема ИНС для прогнозирования объёмов продаж автомобильных аккумуляторных батарей

Таблица 2. Метрики качества модели прогнозирования объёмов продаж автомобильных аккумуляторных батарей

Метрики прогноза	Вариант прогноза	
	набор параметров В1	набор параметров В2
$MAPE_{model}$	2.39 %	3.05 %
$MAPE$	1.93 %	2.77 %
$RMSE$	406915	403593
$R2$	0.993	0.985

На основании полученных результатов сделан вывод о том, что для прогнозирования объёмов продаж автомобильных аккумуляторных батарей целесообразно использовать весь набор метеоданных, так как они позволяют модели выявить закономерности и зависимости в данных.

График прогнозирования объёмов продаж автомобильных аккумуляторных батарей методом ИНС за период с 01.07.2023 по 08.07.2023 представлен на рис. 3.

Фактический объём продаж на диаграмме чёрным цветом за первую неделю июля 2023 г., светло серым – значения прогноза модели с набором данных В2, темно серым – значение прогноза с полным набором метеоданных. По графику установлено, что наибольший объём продаж приходится на 1, 3 и 4 июля, что соответствует более высокой температуре воздуха. Прослеживается, что на графике наилучшие результаты получены моделью с полным набором технологических параметров (В1). Ошибка прогноза уменьшилась на 0.84 % по метрике MAPE, что является существенным улучшением точности прогнозирования объёмов продаж автомобильных аккумуляторных батарей.




Рис. 3. Прогнозирование объёмов продаж автомобильных аккумуляторных батарей на неделю вперёд

Заключение

Проведённые исследования позволили установить, что использование метода, основанного на ИНС для прогнозирования объёмов продаж автомобильных аккумуляторных батарей, является эффективным подходом. Метод ИНС, используемый в исследовании, уменьшает дисперсию прогнозов и обладает устойчивостью к переобучению, что доказывает его функциональность на больших обучающих выборках. Модель, обученная на большой выборке, также более устойчива к случайным аномалиям. В результате исследования сформирована обучающая выборка, выбрана структура данных для прогнозирования объёмов продаж автомобильных аккумуляторных батарей методом ИНС. Сделан вывод о том, что количество наблюдений и параметров в обучающей выборке влияет на конечные результаты прогнозных значений ($B1 \text{ MAPE} = 1,93 \%$, $B2 \text{ MAPE} = 2,77 \%$). Выявление значимых параметров позволяет не включать в обучающую выборку параметры, имеющие наименьший вклад, отсутствие которых позволит сделать прогноз, но с потерей качества.

В условиях постоянного роста стоимости автомобильных аккумуляторных батарей становится критически важным уменьшение ошибок прогнозирования объёмов продаж. Уменьшение ошибок в расчётах позволяет торговым компаниям выстроить наиболее оптимальную бизнес стратегию своего развития и снизить сопутствующие издержки.

В дальнейшем планируется исследовать влияние температуры окружающей среды на уровень продаж во все сезоны года, что позволит более точно определить сезонность данного продукта и более качественно сформировать складские остатки и спрогнозировать выручку организации, что повысит эффективность и прибыльность организации.

Литература

1. Васильев А.А. Методы и модели прогнозирования объёма продаж в маркетинге // Известия Тульского государственного университета. Экономические и юридические

- науки. 2021. № 2. С. 213–216.
2. Reynolds C.F. A Distributed Behavioral Model // Computer Graphics. 1987. Vol. 21, No. 4. P. 25–34.
 3. Eberhart R.C., Kennedy J., Eberhart R.C. New Optimizer Using Particle Swarm Theory // VI International Symposium on Micro Machine and Human Science. 1995. P. 39–43.
 4. Kennedy J., Eberhart R.C. Particle swarm optimization // International Conference on Neural Networks (ICNN'95). Perth, WA, Australia. 1995. P. 1942–1948.
 5. Shi, Y. A modified particle swarm optimizer / Y. Shi, R. Eberhart // IEEE International Conference on Evolutionary Computation. Anchorage, AK, USA. 1998. P. 69–73
 6. Karaboga D. An idea based on honey bee swarm for numerical optimization. Technical report-tr06. Turkey, Kayseri: Erciyes University, 2005. 10 p. URL: http://www.dmi.unict.it/mpravone/nc-cs/materiale/tr06_2005.pdf (дата обращения: 10.06.2024).
 7. Pham D.T., Ghanbarzadeh A., Коç E., Otri S., Rahim S., Zaidi M., Pham D.T. The Bees Algorithm — A Novel Tool for Complex Optimisation Problems. 2005.
 8. Soman S.S., Zareipour H., Malik O., Mandal P. A review of wind power and wind speed forecasting methods with different time horizons // North American Power Symposium. 2010.
 9. Denisova L.A. A mathematical model of a digital control system with variable parameters // Automation and Remote Control. 2012. Vol. 73 (11). P. 1895–1901.
 10. Singh U. et al. Wind energy scenario, success and initiatives towards renewable energy in India—A review // Energies. 2022. Vol. 15 (6). Art. 2291.
 11. George A.F., Alan J.L. Linear Regression Analysis. Hoboken : John Wiley & Sons, 2003. 592 p.
 12. Горшенин А.Ю., Денисова Л.А. Прогнозирование выработки электроэнергии ветро-электростанцией с применением рекуррентной нейронной сети // Известия Тульского государственного университета. Технические науки. 2023. № 4. С. 39–45.

FORECASTING SALES VOLUMES OF AUTOMOTIVE BATTERIES USING THE ARTIFICIAL NEURAL NETWORK METHOD

S.V. Shabunin

Ph.D. Student, e-mail: AgranomMotor@yandex.ru

Omsk State Technical University, Omsk, Russia

Abstract. The article discusses the issues of forecasting sales volumes of automotive batteries of a trade organization by a method based on an artificial neural network. Significant parameters have been determined for forecasting sales volumes of automotive batteries with the required accuracy

Keywords: artificial neural network, forecasting, sales volume of car batteries.

Дата поступления в редакцию: 20.06.2024