

Маруся Иванова

ПРОГНОЗИРАНЕ НА ПРОДАЖБИТЕ С ПОМОЩТА НА ИЗКУСТВЕНИТЕ НЕВРОННИ МРЕЖИ

Направен е опит за въвеждане в същността и методологията на изкуствени невронни мрежи (ИНМ) в маркетинга. За да се очертаят ползите от тяхното аналитично приложение в маркетинговия мениджмънт, се демонстрира решаване на прогностичен проблем чрез прилагане на един от най-широко използваните типове ИНМ – многослойните невронни мрежи с обратно разпространение на грешката. При анализа са използвани данни за продажбите на четири български марки от сектор бързооборотни стоки. Динамичните редове са изследвани за наличие на вариация, отдалечени случаи и нестационарност, тъй като тези характеристики на данните могат значително да повлияят върху прецизността на прогнозите. Доказва се, че ИНМ осигуряват по-прецизни прогнози в сравнение с конвенционалните методи ARIMA и експоненциално изглаждане.

JEL: C12, C45, C52, M31

Интензивното развитие на компютърните и комуникационните технологии увеличава възможностите за набиране и натрупване на данни. Наличието на повече и по-детайлизирана информация обаче само по себе си не води до по-обосновани и по-ефективни маркетингови решения. “Експлозията на данните” ще доведе до по-добри решения само ако мениджърите знаят как да ги организират и използват целесъобразно.¹ Успоредно с това технологичното развитие създава условия за разработването на нов клас аналитични инструменти, които позволяват да се “отсее” полезната информация сред огромните информационни масиви, да се извлече знание, което да се използва при вземането на решения.² Към тях могат да бъдат отнесени изкуствените невронни мрежи, генетичните алгоритми, експертните системи и други методи на изкуствения интелект, които придобиват широка популярност през последните години.

Целта на разработката е да се проучат възможностите и ограниченията на изкуствените невронни мрежи при прогнозиране на продажбите.³ За

¹ *Lilien, G., A. Rangaswamy. Marketing Engineering, Computer-Assisted Marketing Analysis and Planning. Addison-Wesley, Reading, MA, 1998, p. xiii.*

² *Mitchell, D., R. Pavur. Using Modular Neural networks for Business Decisions. - Management Decision, 2002, 40 (1), p. 58.*

³ Прогнозирането на продажбите е един от най-често срещаните проблеми на маркетинговия мениджмънт (и в частност на дейностите по планиране и контрол на маркетинговата дейност), за решаването на които се използват ИНМ. Вж. по-подробно *Guan, B., K. Voges, N. Pope. Artificial Neural Networks in Marketing from 1999 to 2003: A Region of Origin and Topic Area Analysis,*

постигането на тази цел се набелязват следните задачи: *първо*, запознаване със същността и методологията на едни от най-популярните и широко използвани при прогнозирането ИНМ – многослойните невронни мрежи с обратно разпространение на грешката; *второ*, изследване на необходимостта от привеждане на нестационарните данни в стационарни при моделиране с ИНМ; *трето*, пряка съпоставка на резултатите от прогнозирането на продажбите с помощта на ИНМ, експоненциално изглаждане и ARIMA и проверка за наличието на статистически значима разлика между тях; *четвърто*, изследване наличието на зависимост между степента на вариация на данните за продажбите и разликата в резултатите между отделните модели.

Изкуствените невронни мрежи при прогнозиране на продажбите за целите на маркетинговия мениджмънт

ИНМ са клас съвременни, компютърно-базирани методи за извличане на данни от големи, полуструктурирани информационни масиви и тяхното трансформиране в знание за подпомагане вземането на управленски решения. Те представляват опит за опростено аналогизиране на мозъчната структура на човека посредством инструментите на математическата и компютърната логика. Най-общо ИНМ могат да бъдат дефинирани като йерархични структури от взаимосвързани елементи (неврони, възли) за симултантна обработка на данни, което наподобява начина на обработване на информацията и вземане на решения при човека (вж. табл. 1). И въпреки редицата ограничения вследствие опростяването в сравнение с биологичната нервна система през последните години ИНМ намират все по-успешно и широко приложение в икономиката, в т. ч. и в маркетинга.⁴ Силата им е в способността да разрешават проблеми, които са твърде сложни за конвенционалните методи, такива, които нямат или за които е трудно да се намери алгоритмично решение. Към тези проблеми може да се отнесе прогнозирането, което се състои в идентифициране на модели на развитие и каузални зависимости между различни променливи и тяхното проектиране в бъдещето.

Australian and New Zealand Marketing Academy Conference (ANZMAC), 2004; <http://130.195.95.71:8081/WWW/ANZMAC2004/CDsite/papers/Gyan1.PDF>

⁴ Yao, J. et al. Forecasting and Analysis of Marketing Data Using Neural Networks. - Journal of Information Science and Engineering, 14(4), p. 523-545; Rao, C. P., J. Ali. Neural Network Model for Database Marketing in the New Global Economy. - Marketing Intelligence & Planning, Vol. 20, N 1, p. 35-43; Van Wezel, M., W. Baets. Predicting market responses with a neural network: the case of fast moving consumer goods. - Marketing Intelligence & Planning, 1995, Vol.13, N 7, p. 23-30; Curry, B., L. Montinho. Neural Networks in Marketing: Modelling Consumer Responses to Advertising Stimuli. - European Journal of Marketing, 1993, Vol. 27, N 7, p. 5-20.

Таблица 1

Аналогизиране процеса на вземане на решение при човека и процеса на генериране на знание при ИНМ

Типичен процес на вземане на решение при човека	Автоматизиран процес на извличане на знание от данните
1. Дефиниране на проблем и формулиране на цели	1. Дефиниране на проблем
2. Установяване на факти	2. Набиране на минали данни
3. Оценка на фактите	3. Трансформиране и обработване на данните
4. Обобщаване на фактите – контуриране на възможните решения	4. Конструирание и параметризиране на модел
5. Проверка на формулираните изводи	5. Валидиране на модела
6. Преглед на целите	6. Дефиниране на цели
7. Оценка на всички възможни решения съобразно набелязаните цели и избор на най-доброто от тях (това, което се очаква да осигури най-голяма удовлетвореност)	7. Намиране оптималното решение на проблема съобразно дефинираните цели

От гледна точка на маркетинга, в т.ч. и на маркетинговото прогнозиране, ИНМ представляват софтуерен инструмент, който подпомага маркетинговия мениджмънт при вземането на решения с оглед преодоляването на конкретен проблем (прогнозиране на продажбите, пазарния дял и др.). Маркетингът е изключително подходяща за приложението на ИНМ област поради: нелинейността⁵ и на пръв поглед несвързаността⁶ на маркетинговите данни; трудността или невъзможността *a priori* да се дефинират хипотези за вида и формата на връзката между тях; зависимостта на изучавания маркетингов феномен от множество метрични и неметрични фактори. Посочените причини ограничават приложимостта или намаляват прогнозната валидност на традиционните статистически методи за прогнозиране,⁷ тъй като някои от тях допускат нормалност на разпределението на данните, поставят изисквания спрямо равнището на скалиране на използваните променливи (например променливите да са измерени със силни скали), правят предположения относно формата на модела (предполагат наличието на линейна зависимост между променливите) и притежаваните характеристики (тренд, цикличност, сезонност). ИНМ предлагат адекватно решаване на предиктивни проблеми,⁸ тъй като са в състояние да уловят

⁵ Идеята за нелинейността на икономиката и развитието на икономическите субекти е заложена в разработките на много български автори, сред които и на Юлия Узунова (вж. Узунова, Ю. Стратегическа маркетингова активност. Устойчивост на фирмите при промени, Варна, Стено, с. 57-82).

⁶ Решаването на различни маркетингови проблеми е свързано с акумулирането и натрупването на данни, които на пръв поглед изглеждат несвързани помежду си. С помощта на ИНМ обаче могат да се разкрият скрити тенденции и неподозирани зависимости между тях.

⁷ В тази разработка под традиционни (конвенционални) се разбират всички методи, които не попадат в сферата на изкуствения интелект.

⁸ Тук под предиктивен проблем се разбира всеки проблем, свързан с моделиране и прогнозиране на продажбите (или друг пазарен показател), които се разглеждат като функция от

нелинейността (характерна за повечето икономически феномени) в динамичния ред, да се “учат” от примери, без да правят предварителни допускания за разпределението на данните и формата на зависимост между тях. Освен това за разлика от конвенционалните статистическите методи посредством ИНМ се разработват устойчиви модели за прогнозиране и не е необходимо да се изграждат други при появата на нови данни.

Методология на изкуствените невронни мрежи

В теорията на ИНМ се разглеждат редица типове невронни мрежи, всеки от които е специализиран в решаването на един или няколко проблема.⁹ Според използвания подход на обучение те могат да се класифицират на невронни мрежи с администрирано или обучение с учител (*Supervised Learning*) и неадминистрирано обучение или обучение без учител (*Unsupervised Learning*)¹⁰ (фиг.1).

Фигура 1



редица маркетингови променливи или фактори на околната среда. Понятието прогностичен проблем е по-тясно и включва само изглаждане на функцията на продажбите.

⁹ Bigus, J. Data Mining with Neural Networks: Solving Business Problems from Application Development to Decision Support. Mc-Graw Hill, 1996, p. 77.

¹⁰ Нишева, М., Д. Шишков. Изкуствен интелект. Добрич, Интеграл, 1995, с. 146.

Администрираното обучение е подход за обучение на ИНМ, използван при решаването на предиктивни и класификационни проблеми. Същността му се състои в запознаване на ИНМ с изследвания проблем и указване начина за неговото разрешаване. Това означава, че “правилните” (желаните) стойности¹¹ на зависимата променлива (например данни за миналото поведение на продажбите) са известни предварително, а процесът на параметризиране се реализира съобразно размера на грешката, изчислена като разлика между фактичестката и прогнозната стойност.

Невронната мрежа, използваща неадминистрирано правило на обучение, получава информация за изучавания проблем, но не е ориентирана за неговото преодоляване. В процеса на обучение се търси отговор на въпроси като: “По какъв начин са обвързани данните?” и “Каква е степента на вътрешно сходство и външно несходство между тях?”. Основната област на приложение на този тип ИНМ е при сегментирането на пазара.¹²

Според начина на свързване и вътрешната подредба на изкуствените неврони (а оттук и начина на обработване на информационните сигнали) администрираните и неадминистрираните ИНМ могат да се класифицират на такива с право разпространение и такива с обратно разпространение на информационните потоци. Най-популярни и успешни при прогнозирането са многослойните невронни мрежи с право разпространение (*Multi-layered Feedforward Neural Networks*), известни и под наименованието многослоен перцептрон (*Multi-layer Perceptron*). Този тип невронни мрежи се използват в над 80% от изследванията, посветени на конекционисткия подход и неговото приложение при решаване на предиктивни проблеми,¹³ поради което акцентът на тази разработка ще бъде поставен именно върху тях.

Многослойните невронни мрежи с право разпространение представляват йерархична структура от взаимосвързани елементи, организирани в слоеве. ИНМ от този тип притежават един входящ, един или повече скрити (междинни, латентни)¹⁴ и един изходящ слой. При тях информационните потоци се движат от входящия, през скритите към изходящия слой. Ролята на всеки неврон се свежда до обработката на получената информация (посредством определена активизираща функция) и нейното трансфериране към невроните от следващото йерархично равнище. “Ключът” за изучаване структурата на данните и описване зависимостта между изходящия (зависима променлива) и входящите неврони (независими

¹¹ “Правилните” или желаните стойности представляват фактичестките стойности на зависимата променлива.

¹² Вж. по-подробно *Smith, K., J. Gupta*. *Neural Networks in Business: Techniques and Applications for the Operations Researcher*. - *Computers & Operations Research*, 27, 2000, p. 1023-1044.

¹³ *Remus, W., M. O'Connor*. *Neural network time-series forecasting in Principles of forecasting: a handbook for researchers and practitioners*. J. Armstrong (ed.). Kluwer Academic Publ., 2001, p. 246.

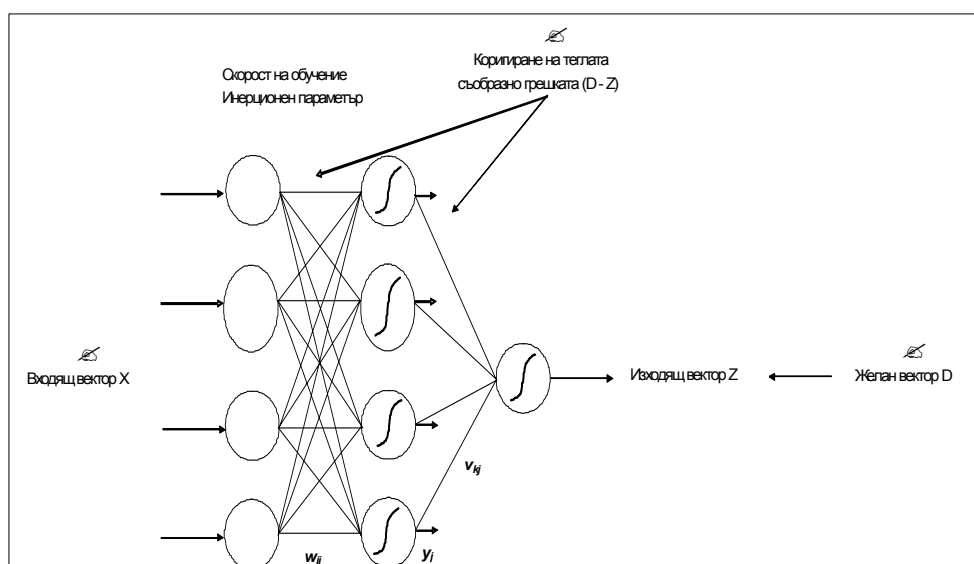
¹⁴ Наличието на скрити слоеве е индикатор за нелинейност на изучаваните явления. Ако нямат скрити слоеве, ИНМ могат да моделират линейни зависимости.

Прогнозиране на продажбите с помощта на изкуствените невронни мрежи

променливи)¹⁵ са невроните от скритите слоеве. Невроните от всеки слой са свързани с останалите посредством връзки, наречени тегла (тегловни коефициенти, синаптични тегла). Последните изпълняват аналогична на коефициентите в регресионния анализ роля, с тази разлика, че могат да се интерпретират. Синаптичните тегла играят ролята на “хранилище” на познанията, натрупани в хода на обучение на мрежата. На фиг. 2 е представен пример за многослоен перцептрон с един скрит слой.

Фигура 2

Многослоен перцептрон с един скрит слой



Параметризирането на модела на ИНМ се извършва чрез *процес на обучение*. Преди да се пристъпи към обучението на невронната мрежа, е необходимо да се възприеме стратегия за разделяне на съвкупността на части (тренировъчна и тестова извадка). По-конкретно, трябва да се вземат решения за броя на извадките и тяхното съотношение. Обикновено съотношението тренировъчна – тестова извадка е 80% - 20%. Следователно оценката и избора на конкретен модел ще се извършва въз основа на 80% от данните, а в останалите 20% ще се тестват неговите прогностични способности.

¹⁵ В своята разработка Sarle обобщава основните понятия, използвани в теорията на ИНМ, и техните аналози в теорията на статистиката. Вж. Sarle, W. Neural networks and statistical models. Nineteenth Annual SAS Users Group International Conference, 1994, p. 2; <http://ann.martinsewell.com/Sarl94.pdf>

Обучението се реализира чрез корекции в стойностите на тегловните коефициенти съобразно възприетия алгоритъм на обучение. Най-популярният и най-широко използван при прогнозирането е алгоритъмът на обратно разпространение на грешката (*Back propagation*). Обучението на ИНМ, използваща този алгоритъм, преминава през три основни фази (вж. фиг. 2):

Фаза 1: Запознаване на ИНМ с проблема и разпространение на информацията от входящия, през скрития(те) към изходящия слой

Стъпка 1: Задаване на първоначални стойности за синаптичните тегла и параметрите на ИНМ. Препоръчва се на отделните тегловни коефициенти да се присвоят ниски, определени на случаен принцип стойности. На този етап се дефинират и стойностите на базовите параметри, използвани при администрираното обучение – скорост на обучение η (*learning rate*) и инерционен параметър μ (*momentum*). Параметърът скорост на обучението служи за контрол върху размера на измененията в синаптичните тегла. Предназначението на инерционния параметър е да се гарантира същата посоката на изменение в тегловните коефициенти, както при последната промяна.

Стъпка 2: Представяне на входящо наблюдение $x = (x_1, x_2, \dots, x_N)$ на ИНМ. Входящият вектор може да включва стойностите на различни независими променливи (цена, разходи за дистрибуция, разходи за реклама и др.) и/или определен брой минали наблюдения (лагови променливи) на изучавания маркетингов феномен (продажби, пазарен дял).

Стъпка 3: Нетният входящ сигнал за всеки скрит неврон (net_j) се изчислява като сума от произведението на стойностите на независимите променливи (x_i) и теглата (w_{ji}), свързващи входящите (i) със скритите (j) неврони. Полученият нетен входящ сигнал, който се трансформира посредством избрана активираща функция f (най-често логистична), служи за изчисляване на изходящия сигнал на скритите неврони (y_j).

$$(1) \quad net_j = \sum_{i=1}^N w_{ji} x_i, \text{ където } N \text{ е броят на независимите променливи}$$

$$(2) \quad y_j = f(net_j) = \frac{1}{1 + e^{-\lambda net_j}} - \text{логистична функция}$$

λ – наклон на активиращата функция; $\lambda \in (0;1)$

e – Неперово число.

Стъпка 4: Подобно на скрития слой се изчислява и нетният входящ сигнал за изходящия неврон (net_k). Последният се определя като сума на изходящите сигнали на скритите слоеве, претеглени с теглата (v_{kj}),

Прогнозиране на продажбите с помощта на изкуствените невронни мрежи

свързващи скритите (j) и изходящите (k) неврони. Крайният резултат (z_k), генериран от ИНМ, се получава чрез трансформиране на net_k посредством избраната активираща функция f .

$$(3) \quad net_k = \sum_{j=1}^J v_{kj} y_j, \text{ където } J \text{ е броят на невроните в скрития слой}$$

$$(4) \quad z_k = f(net_k) = \frac{1}{1 + e^{-\lambda net_k}}$$

Фаза 2: Изчисляване на грешката

Стъпка 5: Изчисляване стойността на грешката като разлика между желанието (d_k) и изходящия вектор (z_k). Желаният вектор при невронните мрежи от този тип на практика представлява входящия вектор.

Фаза 3: Разпространение на информацията за грешката от изходящия, през скрития(те) към входящия слой

Стъпка 6: Актуализиране на теглата, свързващи невроните от скрития и изходящия слой съобразно размера на грешката. Промяната на v_{kj} в епоха t е:

$$(5) \quad \Delta v_{kj(t)} = \mu \Delta v_{kj(t-1)} + \eta \lambda (d_k - z_k) z_k (1 - z_k) y_j, \text{ където}$$

$$t \in [1; T]; \eta, \mu \in (0; 1).$$

Стъпка 7: Използване стойността на грешката за актуализиране и на теглата, свързващи входящите със скритите неврони. Промяната на w_{ji} в епоха t е:

$$(6) \quad \Delta w_{ji(t)} = \mu \Delta w_{ji(t-1)} + \eta \lambda^2 y_j (1 - y_j) x_i \left(\sum_{k=1}^K (d_k - z_k) z_k (1 - z_k) \Delta v_{kj(t)} \right),$$

където K е броят на невроните в изходящия слой.

Стъпка 8: Актуализиране на грешката (E). Измерението на грешката в епоха t е:

$$(7) \quad \Delta E_{(t)} = \Delta E_{(t-1)} + \sum_{k=1}^K (d_k - z_k)^2.$$

Процесът се повтаря, като започва от стъпка 1, докато ИНМ се запознае с всички входящи вектори (това формира една епоха).

Стъпка 9: Описаният процес ще продължи T на брой епохи, като целта е да се намерят онези стойности на теглата w_{ji} , v_{kj} , които минимизират сумата от квадратите на грешките.

Както вече беше споменато, целта на алгоритъма на обратно разпространение на грешката е да се минимизира сумата на квадратичната грешка. Следова-

телно от математическа гледна точка обучението на ИНМ чрез алгоритъма на обратно разпространение на грешката представлява решаване на оптимизационен проблем (намиране на глобалния минимум на функцията на грешката).

След като мрежата е “обучена”, тя трябва да се “захрани” с нови данни, които не са били използвани по време на нейното обучение (тестова извадка). Това е своеобразен начин за тестване на генерализационните способности на ИНМ. При използването на алгоритъма на обратно разпространение на грешката съществува сериозен риск от “свърхобучение” (*overtraining*) на невронната мрежа. Този феномен се наблюдава, когато ИНМ демонстрира по-добри резултати в тренировъчната извадка, отколкото в тестовата. От математическа гледна точка “свърхобучението” е налице, когато е намерен вместо глобален локален минимум на функцията на грешката.

ИНМ и конвенционалните методи за прогнозиране

Прецизността на една прогноза в решаваща степен зависи от използвания метод за прогнозиране. Критичен момент в процеса на маркетинговото прогнозиране е изборът на подходящ прогностичен метод. Стремелът към повишаване прецизността на прогнозите е основен мотив за използване на формални методи за прогнозиране, както и за разработването на нови, по-добри такива.

В зависимост от обема на данните, необходими за разработване на прогнози, могат да се разграничат количествени и евристични методи за прогнозиране.¹⁶ Евристичните методи се използват при липсата на информация за продажбите, например при въвеждане на нови продукти на пазара. С натрупването на “пазарна история” обаче нараства значението и приложимостта на количествените методи за прогнозиране. Последните могат да се подразделят в две групи: методи за анализ на динамични редове и каузални методи (методи за анализ на връзки и зависимости). Първите разработват прогнози чрез анализа на данни за миналото поведение на продажбите и на тази основа – генериране на модел, който “улавя” присъщата им структура. При каузалните методи се изследва зависимостта на изучаваното явление (продажбите) от редица други фактори (маркетингов микс на предприятието и на конкурентите, фактори на макросредата и др.).

Съществуват два основни подхода при анализа на динамични редове¹⁷ - линеен и нелинеен. Линеините, към които се отнасят експоненциално изглаждане и ARIMA, *a priori* допускат линейна форма на модела. Те най-

¹⁶ Изчерпателна класификация на методите за маркетингово прогнозиране може да бъде намерена в разработките на *Armstrong, J.* Selecting Forecasting Methods in Principles of Forecasting: A Handbook for Researchers and Practitioners. J. Armstrong (ed.). Kluwer Academic, 2001, p. 376 и *Mentzer, J., R. Gomes.* Evaluating a Decision Support Forecasting System. - Industrial Marketing Management, 1989, Vol. 18, p. 315-317.

¹⁷ *Morantz, B., T. Whalen, and G. P. Zhang.* A Weighted Window Approach to Neural Network Time Series Forecasting in Neural Networks in Business Forecasting. G. Peter Zhang (ed.). IRM Press, 2004, p. 252-253.

напред правят предположения относно функционалната форма на модела и след това го параметризират. В този смисъл експоненциалното изглаждане и ARIMA са параметрични методи за прогнозиране на продажбите. Предварителното допускане за линейност на формата на модела ограничава възможностите им при моделиране на сложни нелинейни зависимости, присъщи за повечето маркетингови явления.

В зависимост от това дали правят предположения за наличието на сезонност, цикличност или тренд в данните, или не, параметричните методите за анализ на динамични редове се обособяват и в други две групи – фиксирани и отворени.¹⁸ Експоненциалното изглаждане и неговите разновидности спадат към фиксираните методи за анализ на динамични редове, тъй като използват фиксирани уравнения, които се основават на предположението, че динамичният ред притежава един или няколко от основните си компоненти (тренд, цикличност, сезонност). Тези методи са лесни за прилагане, изискват малко данни за генериране на прогноза и са подходящи изключително за еднопериодно прогнозиране.

Отворените методи за анализ на динамични редове, към които спада ARIMA, изследват динамичния ред, за да установят кои компоненти присъстват в него и на тази основа конструират подходящо уравнение за прогнозиране. За да генерират прогнози обаче, те се нуждаят от повече данни за продажбите. Отличават се с висока сложност и чувствителност на резултатите спрямо квалификацията на лицето, разработило прогнозата (много от решенията се вземат експертно). За разлика от фиксираните методи, тази група е подходяща за краткосрочно до средносрочно прогнозиране.

ИНМ могат да се разгледат като клас гъвкави, непараметрични методи за прогнозиране. За разлика от традиционните статистически методи те не формулират хипотези за формата на модела и се “учат” от данните. ИНМ са универсални апроксиматори,¹⁹ тъй като са в състояние да изгладят различен тип функционални зависимости независимо от степента им на сложност и линейност/нелинейност. Това е една изключително ценна характеристика, тъй като всеки предиктивен модел се опитва най-точно да “улови” функционалната връзка между зависимата и независимата(те) променливи. При ИНМ изглаждането на функцията и оценката на параметрите се извършва симултантно.

Подобно на ARIMA, ИНМ се нуждаят от по-голям брой наблюдения за продажбите. Сериозно тяхно предимство пред останали методи за прогнозиране е, че позволяват разработването на устойчив модел за прогнозиране, който не е необходимо да бъде преоценяван при появата на нови данни. Тези мрежи са подходящи както за краткосрочно, така и за средно- и дългосрочно прогнозиране.

¹⁸ *Mentzer, J., R. Gomes.* Цит. съч., с. 316.

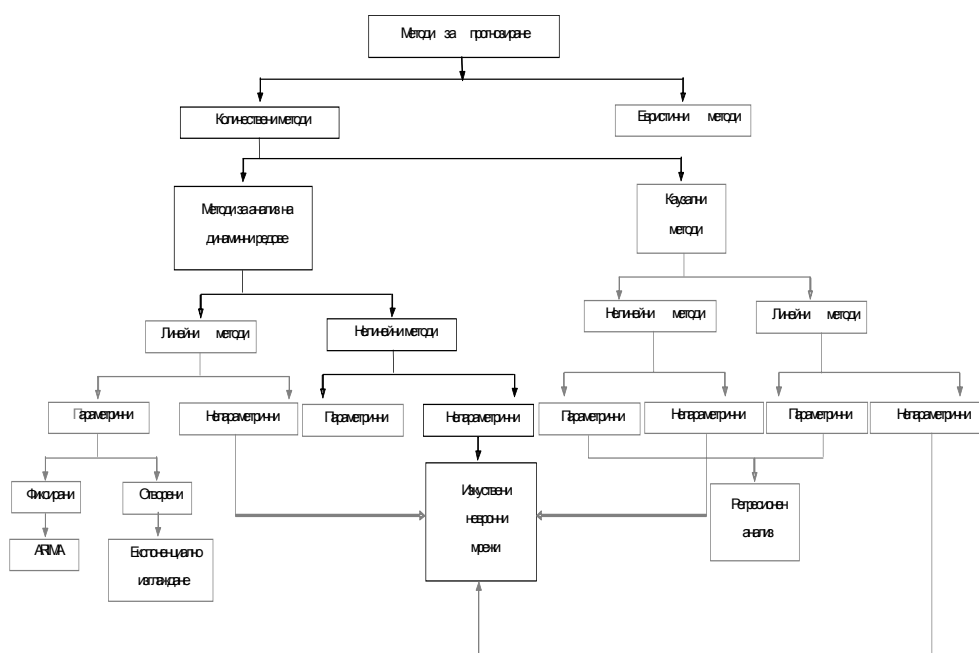
¹⁹ *Zhang, G., B. Patuwo, M. Hu.* Forecasting with Artificial Neural Networks: The state of Art. - International Journal of Forecasting, 1998, Vol. 14, p. 36.

Един от сериозните недостатъци на ИНМ е липсата на систематичен метод за тяхното изграждане, на ясни правила и стандарти за определяне на броя на скритите слоеве и невроните в тях, на стойностите на базовите параметри, на броя на извадките и съотношението между тях. Дори при ARIMA, при която много от решенията се вземат експертно или на база експерименти, се използват статистически техники за изграждане на модела и проверка на неговата адекватност. Но въпреки че често са критикувани за това, че наподобяват поведението на “черна кутия”, желанието да се повиши прецизността на прогнозите може да компенсира липса на прозрачност.

На фиг. 3 е представено мястото на ИНМ сред методите за прогнозиране на продажбите.

Фигура 3

Място на изкуствените невронни мрежи сред методите за прогнозиране



За разлика от повечето конвенционалните статистически методи ИНМ могат успешно да се използват както за прогнозиране на динамични редове, така и за каузално моделиране. Когато ИНМ се използват при решаването на каузален проблем, входящите неврони представляват различни независими променливи. Тогава целта на обучението се свежда до параметризиране на следната функционална зависимост:

Прогнозиране на продажбите с помощта на изкуствените невронни мрежи

$$(8) \quad y = f(x_1, x_2, \dots, x_n),$$

където x_1, x_2, \dots, x_n са независимите променливи (цена, разходи за реклама и др.), y - зависимата променлива (продажби, пазарен дял), а с n е означен броят на независимите променливи.

Тук ИНМ ще се използват като алтернатива на методите за анализ на динамични редове. В този случай входящите неврони представляват определен брой лагови променливи, формирани въз основа на изследвания динамичен ред, а изходящият неврон – бъдещата стойност на изучаваното явление. Прогнозирането се реализира чрез техниката на “плъзгащия се времеви прозорец” (*time windowing*), съгласно която, за да бъдат обучени невронните мрежи и на тази

основа да се генерира прогноза за период $t+1$ (\hat{y}_{t+1}), ще се използват определен

брой лагови променливи $y_t, y_{t-1}, y_{t-2}, \dots, y_{t-n}$ или $\hat{y}_{t+1} = f(y_t, y_{t-1}, y_{t-2}, \dots, y_{t-n})$.

Следователно, за да се определи перспективният обем на продажбите, ще се използват определен брой минали наблюдения, интерпретирайки времето t като единствена независима променлива.

Пример за решаване на прогностичен проблем с помощта на изкуствени невронни мрежи

Очертаването на възможностите и ограниченията на ИНМ ще бъде възможно, като се демонстрира тяхното приложение при реални данни и пряката им съпоставка с конвенционалните методи за прогнозиране. За тази цел ще се използват четири динамични реда с еднаква дължина, илюстриращи развитието на продажбите на четири марки бързооборотни стоки за периода януари 1999 – декември 2003 г.²⁰

Освен задачи с теоретичен характер за постигането на целта са набелязвани и следните задачи с прагматична насоченост:

1. *Съществува ли статистически значима разлика в резултатите на ИНМ, обучени с и без трансформация за стабилизиране на продажбите?*

2. *Съществува ли статистически значима разлика в прецизността (точността) на прогнозите (измерена чрез средния абсолютен процент на грешка), разработени с ИНМ, и традиционните статистически методи (експоненциално изглаждане и ARIMA)? За тази цел се дефинира и подлага на тестване следната хипотеза:*

²⁰ От съображения за конфиденциалност в тази разработка няма да бъдат обявени марките, чиито продажби са обект на прогнозиране. При анализа се използват данни за продажбите на четири български марки от сектор бързооборотни стоки, обособени в две продуктови групи: Продукти 1 и 2 – тестени изделия, и Продукти 3 и 4 – мазнини. Включените в изследването продукти се характеризират с висока интензивност на употреба (Продукти 1 и 2 средно се купуват всеки ден, а Продукти 3 и 4 – веднъж седмично) и попадат в следните ценови диапазони: Продукт 1, 2 и 3 – 0.45 – 0.70 лв., Продукт 4 – 1.80 – 2.00 лв.

$$H_0: MAPE_{NN} = MAPE_{ES} = MAPE_{ARIMA}; H_1: MAPE_{NN} \neq MAPE_{ES} \neq MAPE_{AR}$$

3. Съществува ли корелационна зависимост между равнището на вариация в динамичния ред и разликата в качеството на генерираните от различните модели прогнози?


Резултатите и направените на тяхна основа изводи за прогностичните способности на различните методи не са общовалидни, а са ограничени до вида на продуктите, размера на извадката и използвания тип ИНМ.

Описание и предварителна обработка на изходни данни

Както вече беше споменато, в това изследване всички анализи и заключения за прогностичните способности на различните методи ще се правят въз основа данните за месечните продажби на четири български марки от сектор бързооборотни стоки. За да се осигури съпоставимост на получените резултати, изходните данни се разделят в две извадки: тренировъчна (80%, обхващаща периода януари 1999 – декември 2002 г.) и тестова (20%, включваща периода януари 2003 – декември 2003 г.). Следователно моделите ще се генерират въз основа на 80% от данните, а останалите 20% ще се използват за тестване на техните прогностични способности. С оглед избягване вероятността от “свърхоучение” само при модела на ИНМ се налага допълнително подразделяне на тренировъчното множество в съотношение 90% : 10%. Това означава, че моделът на невронната мрежа ще се построи въз основа на 90% от случаите (от 80-те %), а останалите 10% (валидираща извадка) служат за избор между различни архитектури ИНМ и тестване техните генерализационните способности. На фиг. 4 е представена динамиката на продажбите на четирите продуктови марки в хода на времето.

Фигура 4


Динамика на продажбите за периода 1999 – 2003 г.




а) Продукт 1

б) Продукт 2

Прогнозиране на продажбите с помощта на изкуствените невронни мрежи



с) Продукт 3



д) Продукт 4

Тъй като при повечето методи за прогнозиране се поставят определени изисквания спрямо изходните данни (изискване за стационарност, премахване на липсващи стойности или отдалечени случаи и др.), то преди да се пристъпи към същинската работа (извеждане на модел и прогнозиране), е необходимо те да се подложат на предварителна обработка. Тук резонни са въпросите: Каква е степента на разсейване в изходните данни? Имат ли данните отдалечени случаи? Стационарни ли са изучаваните динамични редове?

1. Изследване степента на разсейване

Теорията на статистиката предлага различни показатели за измерване степента на разсейване. Но тъй като ще правим изводи и пряко ще съпоставяме вариацията в различни съвкупности, представени с различни единици на измерване, най-подходящ е коефициентът на вариация в единици средна стойност.²¹ Граничната стойност, над която може да се говори за наличието на разсейване в данните, е 20%. На табл. 2 са представени коефициентите на вариация за четирите изучавани динамични реда.

Таблица 2

Коефициенти на вариация по продукти

Продукти	Коефициент на вариация (%)
Продукт 1	12.89
Продукт 2	23.43
Продукт 3	26.10
Продукт 4	25.59

²¹ Стойков, Ив. Статистика. Велико Търново, Абагар, 2000, с. 46.

Резултатите от табл. 2 показват неналичие на разсейване при Продукт 1 (12.89% < 20%) и сравнително умерено разсейване при Продукти 2, 3 и 4 (съответно 23.43; 26.10% и 25.59% > 20%).

2. Изследване за наличието на отдалечени случаи

Наличието на отдалечени случаи е специфична форма на разсейване и се наблюдава, когато някой от случаите стои далеч от останалите. Често отдалечените случаи имат уникален характер, тъй като са породени от извънредни събития (производствена авария, внезапна промяна в климатичните условия и др.). Поради тази причина се препоръчва те да бъдат изключени и заместени с нови стойности (различни алгебрични или неалгебрични средни) при дефинирането на модела. За идентифициране наличието на отдалечени случаи ще се използва следният формален метод:

$$(8) \quad \frac{|Mo - Min|}{\bar{X}} > 2 \quad \text{или} \quad \frac{|Max - Mo|}{\bar{X}} > 2,$$

където Mo е модата, Min – минималната стойност, Max – максималната стойност.

Следователно за наличието на отдалечени случаи ще говорим, когато абсолютната разлика между модата и екстремалните стойности на функцията е по-голяма от удвоената средна.

Таблица 3

Идентифициране на наличието на отдалечени случаи

Параметри	Продукт 1	Продукт 2	Продукт 3	Продукт 4
$ Mo - Min $	582 043	1 176 505	250 976	242 555
$ Max - Mo $	219 450	196 081	211 339	149 263
$2 \bar{X}$	2 830 974	2 675 908	852 078	748 434

При продажбите и на четирите продукта не се наблюдават отдалечени случаи, тъй като е нарушено предварително дефинираното условие (Продукт 1 - 582 043 < 2 830 974; Продукт 2 – 1 176 505 < 2 675 908; Продукт 3 – 250 976 < 852 078; Продукт 4 – 242 555 < 748 434).

3. Изследване на нестационарността

Един стохастичен процес е стационарен,²² когато: *първо*, има константна във времето средна; *второ*, има константна във времето дисперсия; *трето*, ковариацията между две наблюдения от динамичния ред зависи единствено от тяхната дистанция във времето, а не от конкретното им място върху времевата ос (установява се посредством корелограмите).

²² Най-общо нестационарните динамични редове характеризират процеси, в които има развитие (тренд). Вж. Манов, А. Статистика със SPSS. С., Рикол-Б, 2000, с. 298.

По подобие на ARIMA някои автори²³ препоръчват, преди да бъдат използвани за обучение на ИНМ, нестационарните динамични редове да се преобразуват (чрез логаритмуване и/или определяне на последователни разлики от някакъв порядък) в стационарни. Една от причините за това се обосновава с факта, че трендът или сезонните колебания могат да имат доминантен характер и по този начин да попречат на ИНМ да идентифицира скритите ефекти в данните за продажбите.

Изследователски интерес представлява въпросът дали нестационарността²⁴ е пречка за ИНМ и дали е необходимо изследваният динамичен ред да бъде стабилизиран, преди да бъде представен на мрежата за обучение.

Резултатите от тестването на хипотезите дават основание да се твърди, че изследваните данни за продажбите са нестационарни, тъй като за всеки от динамичните редове съществува поне една двойка извадки със статистически значими разлики в средните. Доказателство за наличието на нестационарност са и корелограмите по продукти. Корелограмите на Продукти 1, 2 и 3 показват високи позитивни стойности при първите лагове. При Продукт 4 се наблюдава ясно изразена сезонност.

Разработване и оценяване на модели на ИНМ за прогнозиране на продажбите

Преди да се пристъпи към избора на архитектура на ИНМ и определяне стойностите на базовите параметри, е необходимо данните да бъдат трансформирани. Тази трансформация се налага, за да се подпомогне активиращата функция, използвана в междинните и изходящите неврони на

²³ Bigus, J. Цит. съч., с. 49-50; Kline, D. Methods for Multi-Step Time Series Forecasting with Neural Networks in Neural Networks in Business Forecasting. G. Peter Zhang (ed.). IRM Press, 2004, p. 234-235.

²⁴ Нестационарността на изследваните динамични редове може да се установи посредством следната процедура. В резултат от тестове сред множество данни се доказва, че разделянето на съвкупността в определен брой извадки и тестване на хипотези относно разликата на средните и дисперсиите по двойки извадки може да се използва като адекватен критерий за идентифициране на стационарността, респ. нестационарността. В разработката всеки ред с данни за продажбите е разделен в три еднакви по обем извадки. С помощта на *t*-критерия на Стюдънт е тествана хипотеза за наличието на статистически значима разлика между средните на две извадки. И при четирите динамични реда е налице неустойчива във времето средна, тъй като за всеки от тях съществува поне една двойка извадки със статистически значима разлика в средните ($t_{критично}(\alpha=0.05; df=30) = 2.0420$).

Посредством *F*-критерия е тествана хипотезата за липса на разлика в дисперсиите на две извадки. И въпреки че единствено при Продукт 2 се наблюдава неустойчива във времето дисперсия ($F_{критично}(\alpha=0.05; df1=15; df2=15) = 2.8600$), наличието на тренд в изследваните редове дава основание да се заключи, че всички те са нестационарни. Достатъчно условие за нестационарност е наличието на тренд в данните.

Друг формален тест за проверка на стационарността на един динамичен ред е този на *Dickey-Fuller* (вж. Стойков, Ив. Моделиране на шоковете в икономиката. Приложение на количествените методи в икономиката – класика и новаторство. Свищов, 2000, с. 9). В конкретния пример е приложена една от версиите му (*ADF*, *Augmented Dickey-Fuller test*), чрез която още веднъж се потвърждава нестационарността на изходните данни.

мрежата. И тъй като тук информационните сигнали в скритите и изходящи неврони се обработват чрез логистична активираща функция, която приема стойности в интервала от 0 до 1, то и стойностите на продажбите също трябва да се приведат в този интервал. За тази цел данните се нормират, като се разделят на *Евклидовата си норма*.

$$(9) \quad \text{Нормирани данни} = \frac{X_i}{\sqrt{\sum_{i=1}^n (X_i)^2}},$$

където X_i са продажбите в период i , а $\sqrt{\sum_{i=1}^n (X_i)^2}$ - норма на Евклид.

Тъй като и четирите динамични реда са нестационарни, то за продажбите на всеки продукт ще бъдат разработени по два модела на ИНМ, с и без трансформация за стабилизиране (в случая последователни разлики от първи ред).

Всяка невронна мрежа ще разполага с толкова входящи неврона, колкото са лаговите променливи, и един неврон за месеца. За да се осигури съпоставимост на резултатите (методът на експоненциално изглаждане е подходящ за еднопериодно прогнозиране), ще се разработват прогнози за един период. Броят на изходящите неврони съответства на броя на периодите, за които ще се разработва прогноза.

Важно решение при приложението на ИНМ е изборът на критерий за преустановяване обучението. Тук в качеството на такъв критерий се използва прецизността на прогнозата във валидиращата извадка. Изборът на дизайн и оптимална архитектура на ИНМ се извършва въз основа на множество експерименти с данните. Всички ИНМ, въз основа на които се моделират и прогнозираят продажбите на четирите марки бързооборотни стоки, имат четирислойна структура и $\mu = 0.9$. Процесът на обучение стартира при изходна стойност на $\eta = 0.3$, която постепенно намалява до долна гранична стойност 0.01, след което се замества с горна гранична стойност 0.1 и отново спада до минималното гранично равнище 0.01. Последните две стъпки се повтарят до приключване процеса на обучение. Скоростта, с която се реализира спадът в стойността на η , изразена като брой епохи за преминаване от горната към долната му гранична стойност, е 30. По продукти архитектурата на моделите на невронни мрежи е, както следва:

- за Продукт 1 – 5 входящи неврона, 4 скрити неврона, организирани в 2 слоя, и 1 изходящ неврон (5 x 2 x 2 x 1);
- за Продукт 2 – 4 входящи неврона, 5 скрити неврона, организирани в 2 слоя, и 1 изходящ неврон (4 x 3 x 2 x 1);
- за Продукт 3 – 3 входящи неврона, 5 скрити неврона, организирани в 2 слоя, и 1 изходящ неврон (3 x 3 x 2 x 1);
- за Продукт 4 – 5 входящи неврона, 4 скрити неврона, организирани в 2 слоя, и 1 изходящ неврон (5 x 2 x 2 x 1).

За да се установи дали е необходимо, преди да се предоставят за обучение на ИНМ, данните да се подложат на трансформация с оглед тяхното привеждане в стационарен вид, се извършва съпоставка между прецизността на прогнозите, разработени преди и след преобразуване, посредством последователни разлики от първи порядък. За измерване прецизността на прогнозите могат да се приложат различни измерители като средна абсолютна грешка, сума на квадратичната грешка, стандартно отклонение и др., но най-широко използваният²⁵ е средният абсолютен процент на грешка (*Mean Absolute Percentage Error - MAPE*).

За да се даде отговор на въпроса дали привеждането на данните в стационарен вид води до значимо повишаване прецизността на прогнозите, ще се приложи процедура за проверка на хипотези относно разликата в *MAPE* на ИНМ преди и след определянето на последователните разлики от някакъв порядък. Резултатите от тестването на хипотези по изследвани продукти са обобщени в табл. 4.

Таблица 4

Резултати от *t*-теста*

Показатели	Продукт 1	Продукт 2	Продукт 3	Продукт 4
$t_{емп.}$	1.0488	2.9911	1.4588	1.6376

* Критичното значение на *t*-теста при $\alpha = 0.005$ (едностранен тест) и $d_i = 10$ е 3.2500.

Тъй като и при четирите продукта емпиричните значения на критерия са по-ниски от неговите критични стойности (Продукт 1 – $3.25 > 1.0488$; Продукт 2 – $3.25 > 2.9911$; Продукт 3 – $3.25 > 1.4588$; Продукт 4 – $3.25 > 1.6376$), се приема хипотезата за липса на статистически значима разлика в резултатите, получени с и без трансформиране на данните. Следователно процедурата по стабилизиране на реда е излишна, тъй като не води до съществено повишаване прецизността на прогнозите.

За да се идентифицират възможностите и ограниченията на ИНМ при прогнозирането на продажбите, е необходима пряката им съпоставка с двата най-популярни линейни статистически методи за прогнозиране – експоненциално изглаждане и ARIMA²⁶. На табл. 5 са представени използваните за целите на анализа линейни модели.

²⁵ Mentzer, J., K. Kahn. Forecasting Technique Familiarity, Satisfaction, Usage, and Application. - Journal of Forecasting, 1995, Vol. 14, p. 473.

За изчисляване на средния абсолютен процент на грешка се използва следната формула:

$$(10) \quad MAPE = \frac{\sum_{t=1}^N \frac{|Y_t - F_t|}{Y_t}}{N} \cdot 100,$$

където Y_t са фактическите продажби, F_t – прогнозната стойност за продажбите, N – броят периоди.

²⁶ Технологията за провеждане на тези методи няма да бъде представена, тъй като те не са обект на изследване в разработката. За повече подробности вж. Newbold, P., T. Bos. Introductory Business Forecasting. South-Western, 1994, p. 158-316; Панайотов, Д. Планови методи във

Таблица 5

Линейни параметрични модели*

Модел	Продукт 1	Продукт 2	Продукт 3	Продукт 4
ARIMA	ARIMA (0;1;0) b=10129.14 (0.3742)	ARIMA (1;1;0) B=11275.08 (0.6010) $\phi=0.2477$ (0.0602)	ARIMA (0;1;1) b=5439.18 (0.1072) $\theta=0.7165$ (0.0000)	ARIMA (0;0;1)(1;1;0) ₁₂ $\theta=-0.5516$ (0.0000) $s\phi=-0.4567$ (0.0036)
Експоненциално изглаждане	$\alpha=0.97$ $\gamma=0.00$	A=0.97 Г=0.6 Ф=0.5	$\alpha=0.33$ $\gamma=0.00$ $\phi=0.9$	$\alpha=0.00$ $\gamma=0.2$ $\delta=0.9$

* За изглаждане на продажбите с помощта на експоненциалното изглаждане са използвани следните разновидности на метода: (1) Продукт 1 – модел на Холт (линеен тренд); (2) Продукт 2 – заглъхващ тренд; (3) Продукт 3 – заглъхващ тренд и (4) Продукт 4 – линеен тренд, адитивна сезонност. Означенията в таблицата за метода на експоненциалното изглаждане са, както следва: α – базов параметър, γ – параметър за тренда, ϕ – параметър за заглъхващ тренд и δ – параметър за сезонност. Използваните означения за ARIMA са: b – константа; ϕ – параметър за авторегресия от първи ред; $s\phi$ – параметър за сезонна авторегресия от първи ред; θ – параметър за плъзгащи се средни от първи ред.

В скобите е посочена статистическата значимост на оценките на параметрите. Както се вижда, към повечето от оценките на параметрите трябва да се отнасяме с резерви, тъй като са статистически незначими (равнище на значимост, по-голямо от 0.05). И при двата метода прогнозните стойности не прехвърлят 95-процентните доверителни интервали.

В резултат от анализа на корелограмите на грешките могат да се направят следните коментари: *Първо*, Продукти 1 и 2 – както при експоненциалното изглаждане, така и при ARIMA автокорелационните функции на грешките показват пик на лаг 6. Вох-Ljung статистиката е значима при лаг 6 (равнище на значимост, по-малко от 0.05), което подсказва наличието на периодично поведение с 6-месечен цикъл. *Второ*, Продукт 3 - при експоненциалното изглаждане и ARIMA автокорелационните функции на грешките показват пик на лагове 3 и 4. Освен това Вох-Ljung статистиката е значима при тези лагове, което означава, че и тук се отразява структура, която не е обяснена от използваните модели. *Трето*, Продукт 4 – при експоненциалното изглаждане се наблюдава значима автокорелация на грешката при лагове 1 и 2. Използваният за този продукт ARIMA-модел осигурява статистическа незначима автокорелация на грешките. Следователно единствено използваният при Продукт 4 ARIMA-модел адекватно описва структурата на изходните данни.

фирмения бизнес. Свищов, Стопански свят, 1994; Тонкова, Ст. Методи и модели за прогнозиране и планиране на народното стопанство. Свищов, СА "Д. А. Ценов", 1986.

Съпоставката на използваните в настоящата разработка методи за прогнозиране на продажбите се извършва въз основа достигнатото от тях равнище на прецизност. Получените стойности на *MAPE* свидетелстват за най-добри прогностични способности на метода на ИНМ (табл. 6).

Таблица 6

Стойности на *MAPE* за различните методи по продукти (%)

Тестова извадка	$MAPE_{NN}$	$MAPE_{ES}$	$MAPE_{ARIMA}$
Продукт 1	0.1332	4.1900	4.1916
Продукт 2	0.1663	5.2770	5.6558
Продукт 3	2.6759	26.0634	27.0931
Продукт 4	0.4611	10.7013	16.3199

ИНМ са единственият метод, който перфектно апроксимира изследваните функционални зависимости (в %): Продукт 1 – $0.1332 < 4.1900 < 4.1916$; Продукт 2 – $0.1663 < 5.2770 < 5.6558$; Продукт 3 – $2.6759 < 26.0634 < 27.0931$; Продукт 4 – $0.4611 < 10.7013 < 16.3199$. Те еднакво добре се справят с динамични редове с различно равнище на вариация. Нестационарността не е проблем за ИНМ и без предварителни трансформации успяват да “прозрат” истинската същност на данните.

Тестване на хипотези

Изборът на модел, въз основа на който да се разработят прогнози за продажбите, може да се извърши въз основа на пряката съпоставка на *MAPE* (или друг измерител на прецизността) за всички използвани модели. И въпреки че за всички изследвани продукти ИНМ дават най-добро решение, т.е. осигуряват най-ниско равнище на грешка, резонен е въпросът дали съществува статистически значима разлика в резултатите на различните методи. За тази цел се провежда процедура за проверка на хипотези относно разликата в *MAPE* по двойки методи. Резултатите от тестването на хипотези по изследвани продукти са обобщени в табл. 7.

Таблица 7

Резултати от *t*-теста по продукти*

Показатели	Продукт 1	Продукт 2	Продукт 3	Продукт 4
$t_{емп.}$ Експоненциално изгл. / ИНМ	3.3382	3.3436	2.2079	5.9057
$t_{емп.}$ ARIMA / ИНМ	3.3436	3.5711	2.2602	5.2973

* Критичното значение на *t*-теста при $\alpha = 0.025$ (едностранен тест) и $d_f = 11$ е 2.2010.

Изводът, който може да се направи, е, че съществува статистически значима разлика в получените резултати при ИНМ и експоненциално изглаждане и ИНМ и ARIMA. Причините за това могат да се търсят в природата на ИНМ и техния нелинеен характер.

Друг изследователски въпрос, на който се търси отговор, е свързан с проверка за наличието на корелационна зависимост между равнището на вариация на динамичния ред и разликата в прецизността по двойки методи. Необходимата информация за определяне силата на тази връзка се съдържа в табл. 8.

Таблица 8

Тестване корелационната зависимост между вариацията и разликата в прецизността

Тестова извадка	Коефициент на вариация	MAPE Експ.изгл./ИНМ	MAPE ARIMA/ИНМ
Продукт 1	0.1289	0.040567	0.040584
Продукт 2	0.2343	0.051107	0.054895
Продукт 3	0.2610	0.233875	0.244172
Продукт 4	0.2559	0.102402	0.158588

С помощта на коефициента на Пирсън е установено наличието на умерени положителни зависимости между: *първо*, равнището на вариация и разликата в грешката при експоненциалното изглаждане и ИНМ (0.6248) и *второ*, равнището на вариация и разликата в грешката при ARIMA и ИНМ (0.7214). Въпросът обаче е дали в действителност съществува подобна корелационна връзка, или показаната зависимост се дължи на действието на случайни фактори. За да се даде отговор на този въпрос, трябва да се използва *t*-тестът. Последният служи за измерване на статистическата значимост и надеждност на установения коефициент. И в двата случая емпиричната стойност е по-ниска от критичната при равнище на значимост $\alpha = 0.05$ и степен на свобода 2: $1.1317 < 4.303$ и $1.4732 < 4.303$. Следователно получените резултати не дават основание да се твърди, че съществува положителна корелационна връзка между степента на вариация и разликата в прецизността по двойки методи.

Обобщавайки резултатите от направеното изследване, можем да заключим, че:

- При прогнозиране продажбите на бързооборотни стоки ИНМ осигуряват по-точни прогнози в сравнение с методите ARIMA и експоненциално изглаждане.
- Привеждането на данните в стационарен вид не води до съществено повишаване прецизността на генерираните с ИНМ прогнози.
- Не може да се говори за наличието на положителна корелационна зависимост между равнището на вариация в данните и разликата в прецизността по двойки методи.

*

За да се очертаят ползите от приложението на ИНМ, се демонстрира решаване на реален прогностичен проблем с помощта на едни от най-популярните методи – многослойни невронни мрежи с обратно разпространение на грешката. За тази цел се използват данни за продажбите на четири български марки от сектор бързооборотни стоки. Възможността за алтернативно прогнозиране посредством различни методи прави неизбежна пряката съпоставка между тях. Тук като критерий за сравнение на резултатите от прогнозирането се използва показателят среден абсолютен процент на грешка. И въпреки че получените резултати не са общовалидни и не позволяват извеждането на генерални заключения за предиктивните способности на ИНМ, все пак може да се заключи, че в сравнение с конвенционалните методи ARIMA и експоненциално изглаждане и при четирите продуктови марки многослойните невронните мрежи с обратно разпространение на грешката осигуряват най-точни прогнози за продажбите. Този тип невронни мрежи се доказва като перфектен апроксиматор, който с достатъчно високо равнище на прецизност може да изглади различни динамични редове независимо от степента им на вариация и типа им на нестационарност.

Съществуват множеството отворени въпроси в областта на ИНМ, които заслужават внимание и вложение на интелектуални усилия и не са намерили място в тази разработка. Научен интерес ще представлява оценяването на възможностите и ограниченията на различни типове ИНМ, в т. ч. многослоен перцептрон, радиално-базисни невронни мрежи (*Radial Basis Neural Networks*) и рекурентни невронни мрежи (*Recurrent Neural Networks*) при изграждането на предиктивни модели на продажбите и пазарния дял, като в качеството на независими променливи се използва не само факторът време, но и елементите на маркетинговия микс (собствен и на конкурентите).

Във фокуса на нашето изследване е поставен единствено критерият прецизност на прогнозите, тъй като е най-важен при оценка ефективността на методите за прогнозиране. Всеки предиктивен метод обаче трябва да бъде оценяван и по отношение на критерии като сложност на метода, необходимо време за реализирането на изчислителната процедура и др. Това предполага разработването и използването на системи за експертно оценяване на ефективността на методите.

30. VI. 2005 г.