

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ ЭФФЕКТИВНОСТИ СУММАРНО-РАЗНОСТНОГО ПЕЛЕНГАТОРА НА БАЗЕ АНТЕННОЙ РЕШЕТКИ С ПОДРЕШЕТКАМИ И ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Зайцев И.А.¹, аспирант, Кривицкий П. Д.¹, студент гр. 241201

Белорусский государственный университет информатики и радиоэлектроники¹
г. Минск, Республика Беларусь

Козлов С.В. – д-р техн. наук, проф.

Аннотация. Представлены результаты исследования эффективности нейросетевого метода измерения угловых координат для суммарно-разностного пеленгатора на базе антенной решеткой с подрешетками. Рассмотрен процесс формирования датасета, включающий моделирование приемных каналов с учетом амплитудно-фазочастотных неидентичностей, углового сканирования и перестройки несущей частоты. Предложена архитектура измерителя на основе многослойного перцептрона. На основе статистического моделирования показано, что применение нейросети позволяет практически полностью устранить систематические ошибки пеленгования, обусловленные неидентичностями каналов, и обеспечить точность, близкую к потенциально достижимой.

Ключевые слова. Антенная решетка, подрешетка, суммарно-разностный пеленгатор, искусственная нейронная сеть, многослойный перцептрон, датасет, амплитудно-фазочастотные неидентичности.

Современные радиолокационные системы с антенными решетками (АР) предъявляют высокие требования к точности измерения угловых координат (УК) целей. Классические суммарно-разностные пеленгаторы [1, 2], использующие амплитудную обработку, чувствительны к амплитудно-фазочастотным неидентичностям (АФЧН) [3] приемных каналов, которые возникают из-за разброса параметров элементов, нестабильности трактов, а также при перестройке частоты и в процессе углового сканирования. Традиционным способом борьбы с этим является калибровка, требующая значительных временных и вычислительных затрат.

В последние годы активно исследуются методы применения искусственных нейронных сетей (ИНС) для обработки радиолокационной информации. ИНС способны аппроксимировать сложные нелинейные зависимости и «запоминать» поправочные коэффициенты на этапе обучения, что позволяет компенсировать аппаратные погрешности без явного введения корректирующих таблиц. В настоящей работе рассматривается применение ИНС в суммарно-разностном пеленгаторе.

Целью исследования является экспериментальная оценка эффективности нейросетевого подхода к измерению УК применительно к варианту суммарно-разностного пеленгатора с ИНС [4], включая анализ качества сформированного датасета, выбор архитектуры сети и сравнение точности с потенциально достижимой границей Крамера-Рао.

Формирование входных и выходных векторов

Формирование сигналов на выходах приемных каналов и их обработка выполнялись в соответствии с классическим суммарно-разностным методом с учетом АФЧН приемных каналов подрешеток.

Входными признаками для ИНС являются семь действительных входных сигнала. Первая часть включает амплитуды $|\dot{Y}_{\Delta\alpha(\beta)}^H|$ и фазы $\Psi_{\Delta\alpha(\beta)}^H$ сигналов разностных каналов $\dot{Y}_{\Delta\alpha}$, $\dot{Y}_{\Delta\beta}$, нормированные относительно суммарного канала \dot{Y}_{Σ} :

$$\dot{Y}_{\Delta\alpha}^H = \frac{\dot{Y}_{\Delta\alpha}}{\dot{Y}_{\Sigma}} = |\dot{Y}_{\Delta\alpha}^H| e^{j2\pi\Psi_{\Delta\alpha}^H}; \Psi_{\Delta\alpha}^H = \frac{\arg \dot{Y}_{\Delta\alpha}^H}{2\pi};$$

$$\dot{Y}_{\Delta\beta}^H = \frac{\dot{Y}_{\Delta\beta}}{\dot{Y}_{\Sigma}} = |\dot{Y}_{\Delta\beta}^H| e^{j2\pi\Psi_{\Delta\beta}^H}; \Psi_{\Delta\beta}^H = \frac{\arg \dot{Y}_{\Delta\beta}^H}{2\pi}.$$

Второй частью является вектор условий наблюдения, состоящий из азимута фазирования α_{ph} , угла места фазирования β_{ph} и несущей частоты f_0 . Нормировка условий наблюдения выполнена согласно выражениям:

$$\alpha_{ph}^H = \frac{\alpha_{ph} - \alpha_{\min}}{\alpha_{\max} - \alpha_{\min}}; \beta_{ph}^H = \frac{\beta_{ph} - \beta_{\min}}{\beta_{\max} - \beta_{\min}}; f_0^H = \frac{f_0 - f_{\min}}{f_{\max} - f_{\min}}.$$

где $\alpha(\beta)_{\max}$, $\alpha(\beta)_{\min}$ – максимальные и минимальные значения угла наблюдения по азимуту (углу места) соответственно; f_{\max} , f_{\min} – максимальные и минимальные значения несущей частоты.

Выходными величинами служат абсолютные угловые отклонения сигнала от направления фазирования в радианах:

$$\Delta\alpha = \alpha - \alpha_{ph}; \Delta\beta = \beta - \beta_{ph}$$

При формировании весовых коэффициентов сигналов суммарного, разностного по азимуту и углу места каналов использовались идеальные (неискаженные) модели диаграмм направленности (ДН) подрешеток, тогда как полезный сигнал на выходах подрешеток формировался с учетом реальных АФЧН приемных каналов. Именно это различие между модельными и реальными каналами приводит к возникновению систематических ошибок при классической обработке.

Модель амплитудно-фазочастотных неидентичностей

АФЧН можно разделить на два типа: АФЧН радиотрактов, определяемую исключительно несущей частотой, и АФЧН антенной решетки, возникающую при угловом сканировании из-за различий параметров фазовращателей, аттенуаторов.

АФЧН радиотрактов задавались по формуле:

$$\dot{K}(n, f_0) = (1 + \xi_A(n, f_0)) e^{j\xi_\varphi(n, f_0)},$$

где n – номер подрешетки; $\xi_A(n, f_0)$ – случайная величина, распределенная по нормальному закону с нулевым средним и среднеквадратическим отклонением намного меньше единицы; $\xi_\varphi(n, f_0)$ – случайная величина, распределенная по нормальному закону с нулевым средним и среднеквадратическим отклонением в интервале $0 \dots 30^\circ$.

АФЧН антенной решетки моделировалось согласно формуле:

$$\dot{F}(n, n_\alpha, n_\beta, f_0) = (1 + v_A(n, n_\alpha, n_\beta, f_0)) e^{jv_\varphi(n, n_\alpha, n_\beta, f_0)},$$

где n_α – азимут направления фазирования; n_β – угол места направления фазирования; $v_A(n, n_\alpha, n_\beta, f_0)$ – случайная величина, распределенная по нормальному закону с нулевым средним и среднеквадратическим отклонением намного меньше единицы; $v_\varphi(n, n_\alpha, n_\beta, f_0)$ – случайная величина, распределенная по нормальному закону с нулевым средним и среднеквадратическим отклонением в интервале $0 \dots 60^\circ$.

Тогда, результирующая АФЧН приемных каналов подрешеток задавалась как:

$$\dot{K}_{\text{АФЧН}} = \dot{K}(n, f_0) \cdot \dot{F}(n, n_\alpha, n_\beta, f_0).$$

Формирование массива неидентичностей для всех частот, направлений фазирования и подрешеток выполняется однократно и сохраняется для обеспечения воспроизводимости.

Моделирование условий наблюдения

Для формирования обучающего датасета использовалось численное моделирование условий работы антенной решетки. Размер датасета составил $2^{19} = 524288$ выборок. Формирование датасета реализовано с использованием векторизованных функций для повышения производительности.

Для каждой выборки датасета случайным образом задавались:

- несущая частота в диапазоне 9,9...10,1 ГГц с шагом 10 МГц;
- направление фазирования подрешеток случайно задавалось по азимуту в секторе $\pm 45^\circ$ и по углу места в секторе $0 \dots 45^\circ$;
- межэлементное расстояние было выбрано в соответствии с центральной частотой и составляло 1,5 см.
- ширина главного лепестка ДН антенной решетки по азимуту $2,8^\circ$ и по углу места $6,4^\circ$.
- среднеквадратичные значения АФЧН $\sigma_A = v_A = 0,1$ и $\sigma_\varphi = v_\varphi = 15^\circ$;
- угловое положение полезного сигнала в пределах половины ширины ГЛ ДН относительно направления фазирования;
- отношение сигнал/шум (SNR) в подрешетке, принимаемое равным 50 дБ для обучения ИНС. Для оценки точности варьировалось от 0 до 50 дБ.

Архитектура нейросетевого измерителя угловых координат

Для решения задачи оценки угловых отклонений сигнала от направления фазирования была выбрана архитектура многослойного перцептрона (MLP). Выбор данной архитектуры обусловлен характером входных данных. Входные признаки представляют собой агрегированные характеристики сигналов суммарного и разностных каналов, не обладающие выраженной пространственной или временной структурой. В связи с этим применение сверточных или рекуррентных нейронных сетей является избыточным, а использование MLP позволяет эффективно аппроксимировать требуемую нелинейную зависимость.

Архитектура сети включает входной слой, четыре скрытых слоя и выходной слой. Размерности слоев выбраны следующим образом: $7 \rightarrow 512 \rightarrow 256 \rightarrow 128 \rightarrow 64 \rightarrow 2$. Увеличенная размерность первого скрытого слоя обеспечивает формирование большого признакового представления, необходимого для учета сложных нелинейных эффектов, обусловленных АФЧН приемных каналов. Последующее

постепенное уменьшение размерности реализует сжатие признакового пространства и способствует выделению наиболее информативных компонент.

Во всех скрытых слоях используется функция активации *ReLU*, обеспечивающая высокую скорость сходимости обучения и позволяющая эффективно моделировать нелинейные зависимости без эффекта насыщения, характерного для сигмоидальных функций. Выходной слой является линейным, что соответствует задаче регрессии.

Архитектура нейросети представлена на рисунке 1:

```
class DeepMLP(nn.Module):
def __init__(self, input_dim):
    super(DeepMLP, self).__init__()
    self.net = nn.Sequential(
        nn.Linear(input_dim, 512),
        nn.ReLU(),
        nn.Linear(512, 256),
        nn.ReLU(),
        nn.Linear(256, 128),
        nn.ReLU(),
        nn.Linear(128, 64),
        nn.ReLU(),
        nn.Linear(64, 2)
    )

def forward(self, x):
    return self.net(x)
```

Рисунок 1 – Архитектура искусственной нейронной сети – измерителя угловых координат

Выход сети содержит две компоненты, соответствующие оценкам угловых отклонений сигнала от направления фазирования по азимуту и углу места. Использование единой модели для одновременной оценки двух координат позволяет учитывать их взаимосвязь, что в ряде случаев может способствовать повышению точности оценивания по сравнению с независимым обучением, однако данный эффект зависит от структуры данных и не является гарантированным.

Выбранная архитектура обеспечивает достаточную аппроксимационную способность для компенсации искажений, вызванных амплитудно-фазочастотными неидентичностями, а также нелинейностью дискриминационных характеристик суммарно-разностного пеленгатора при перестройке частоты и угловом сканировании.

Обучение нейросети и анализ результатов

Обучение ИНС-измерителя УК проводилось на синтетически сформированном датасете. Для обеспечения корректной работы модели все входные признаки были предварительно нормированы к диапазону $[0, 1]$, что позволило стабилизировать процесс обучения и ускорить сходимость алгоритма стабилизации.

Датасет был разделен на обучающую и контрольную выборки. Контрольная выборка не использовалась в процессе обновления весов и применялась исключительно для оценки обобщающей способности модели.

В качестве функции потерь использовалась среднеквадратичная ошибка (*MSE*), широко применяемая в задачах регрессии. Данная функция потерь минимизирует средний квадрат отклонения предсказанных значений угловых координат от истинных, что обеспечивает высокую чувствительность к большим ошибкам. Это особенно важно в задаче пеленгования, где редкие, но значительные отклонения оценки могут приводить к существенным ошибкам в определении положения цели.

Оптимизация параметров нейросети выполнялась с использованием алгоритма *Adam*, обладающего адаптивной настройкой скорости обучения для каждого параметра. Это обеспечивает устойчивую сходимость и снижает требования к ручному подбору гиперпараметров.

Обучение проводилось на протяжении большого числа эпох, что обусловлено высокой сложностью аппроксимируемой зависимости. Нейросеть должна восстанавливать отображение, учитывающее влияние АФЧН, частоты сигнала, направления сканирования и нелинейных характеристик суммарно-разностного пеленгатора. Такая зависимость имеет сложную многомерную структуру и требует значительного числа итераций для точной аппроксимации.

Для анализа процесса обучения были построены зависимости функции потерь на обучающей и контрольной выборках от номера эпохи представленные на рисунке 2.

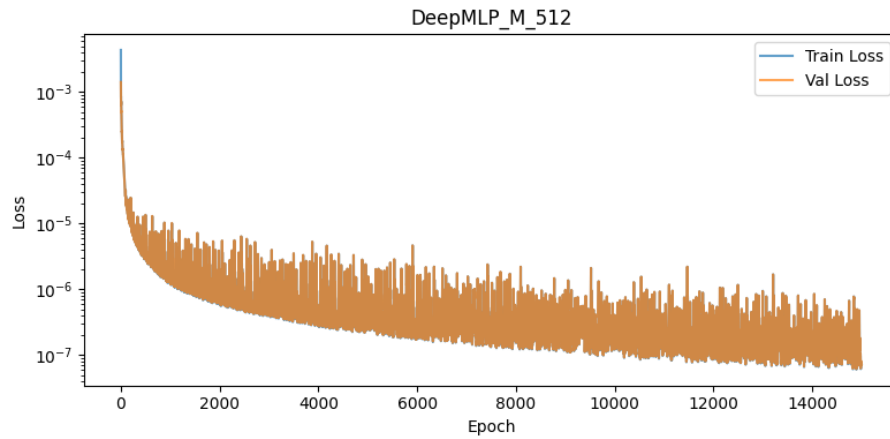


Рисунок 2 – Зависимости функции потерь от номера эпохи

Анализ графика показывает, что процесс обучения можно условно разделить на несколько этапов. На начальном этапе наблюдается резкое снижение функции потерь, что соответствует быстрому захвату моделью грубой структуры зависимости между входными признаками и выходными параметрами. Далее снижение ошибки замедляется, и процесс обучения переходит в стадию тонкой настройки параметров модели.

Характерной особенностью графика является наличие флуктуаций значения функции потерь на обучающей и контрольной выборках. Эти колебания обусловлены стохастическим характером алгоритма оптимизации, а также сложностью аппроксимируемой зависимости. При этом амплитуда флуктуаций постепенно уменьшается по мере обучения, что свидетельствует о стабилизации процесса оптимизации.

На поздних этапах обучения наблюдается выход функции потерь на плато, при котором дальнейшее увеличение числа эпох не приводит к значимому улучшению качества. Это указывает на достижение моделью предельной аппроксимационной способности в рамках выбранной архитектуры.

Важно отметить, что кривые функции потерь для обучающей и контрольной выборок имеют близкий характер поведения и не демонстрируют систематического расхождения. Это свидетельствует об отсутствии переобучения и хорошей обобщающей способности модели. Это косвенно подтверждает, что дальнейшее снижение ошибки ограничено не переобучением модели, а влиянием шумов и неопределенностью входных данных.

Результаты исследования и их анализ

Далее представлены результаты численного моделирования, направленного на оценку эффективности нейросетевого измерителя угловых координат и его сравнение с суммарно-разностным методом без калибровки и использования поправочных таблиц. Для оценки точности использовались тестовые выборки, не участвовавшие в обучении. Оценка точности выполнялась с помощью межквартильного размаха IQR и 90-процентной ширины распределения ошибок:

$$IQR = q_{0,75} - q_{0,25}; \quad \Omega_{0,9} = q_{0,95} - q_{0,05},$$

где q_p – квантиль функции распределения ошибки.

Потенциально достижимая точность оценивалась по нижней границе Крамера-Рао. Результаты моделирования для различных значений SNR приведены на рисунках 3–7.

Суммарно-разностный метод

На рисунке 3 представлены ошибки измерения угловых координат для классической суммарно-разностной системы при отсутствии коррекции АФЧН и при значении отношения сигнал/шум 50 дБ.




Рисунок 3 – Ошибки для суммарно-разностной системы при SNR в подрешетке 50 дБ при отсутствии поправок

При использовании только суммарно-разностного пелингования (без ИНС) средняя ошибка измерения азимута составила $0,10^\circ$ при выборочном СКО $0,32^\circ$, межквартильном размахе IQR равном $0,293^\circ$, и ширине распределения, содержащей 90% всех измерений $1,092^\circ$. По углу места средняя ошибка равна $-0,51^\circ$, СКО составляет $0,55^\circ$, $IQR = 0,486^\circ$, а 90%-ная ширина равно $1,832^\circ$.

Относительно ширины главного лепестка: средняя ошибка составляет 3,6% от ширины луча по азимуту и 8,0% по углу места, СКО по азимуту ($0,32^\circ$) составляет 11,4% от $2,8^\circ$, а СКО по углу места ($0,55^\circ$) – 8,6% от $6,4^\circ$. Свою очередь 90% ошибок укладываются в интервал шириной 39% от ширины луча по азимуту и 28,6% по углу места. Анализ гистограмм показывает большой диапазон разброса ошибок.

Для ошибок по азимуту значение параметра хи-квадрат критерия Пирсона составило очень большую величину, что отвергает гипотезу о нормальности распределения ошибок. Это же обстоятельство хорошо видно из выборочных гистограмм, где сплошная кривая соответствует нормальной плотности распределения вероятности ошибки для выборочных значений мат ожидания и СКО.

Анализ результатов показывает, что даже при высоком уровне SNR наблюдаются значительные систематические ошибки, вследствие чего математическое ожидание отклонений существенно отличается от нуля как по азимуту, так и по углу места, причем для угла места смещение выражено сильнее из-за одностороннего характера отклонений. АФЧН, возникающая при перестройке частоты и угловом сканировании, приводит к существенным искажениям, обусловленным несовпадением реальных характеристик приемных каналов с идеализированной моделью.

Нейросетевой метод

На рисунке 4 представлены гистограммы оценок измерения угловых координат после обучения MLP при SNR в подрешетке 50 дБ, что позволяет напрямую сравнить эффективность нейросетевой коррекции с классическим суммарно-разностным алгоритмом без коррекции.




Рисунок 4 – Ошибки для контрольной выборки после обучения, SNR в подрешетке 50 дБ

Для азимута после обучения MLP получены следующие показатели: средняя ошибка $-0,01^\circ$, среднеквадратическое отклонение (СКО) равно $0,020^\circ$, межквартильный размах $IQR = 0,024^\circ$, а ширина

интервала, содержащего 90% измерений, равна $0,062^\circ$. Для угла места: средняя ошибка равна $-0,02^\circ$, СКО = $0,022^\circ$, $IQR = 0,026^\circ$, 90%-ная ширина = $0,068^\circ$.

Относительно ширины главного лепестка: по азимуту СКО составляет 0,71% от ширины луча, а 90%-ый интервал – 2,2%; по углу места СКО равен 0,34%, 90%-ый интервал равен 1,06%.

Данные показатели свидетельствуют о высокой точности измерений.

Применение многослойного перцептрона в составе суммарно-разностного пеленгатора позволяет практически полностью устранить систематические ошибки. После обучения средние ошибки составляют сотые доли градуса, что близко к нулю. Разброс ошибок уменьшается в десятки раз – от $0,32^\circ \dots 0,55^\circ$ до $0,020^\circ \dots 0,022^\circ$ по СКО, и от $1,09^\circ \dots 1,83^\circ$ до $0,062^\circ \dots 0,068^\circ$ по 90%-ному интервалу. Что подтверждает способность ИНС аппроксимировать сложную нелинейную калибровочную функцию, зависящую от условий наблюдения.

Следует отметить, что результаты при высоких значениях SNR (50–30 дБ) оказываются качественно близкими, поскольку влияние шума в этих условиях незначительно по сравнению с ошибками, обусловленными АФЧН. В связи с этим дальнейший анализ нейросетевого алгоритма проводится при значениях SNR в диапазоне 20...0 дБ.

Влияние отношения сигнал/шум

Результаты работы нейросетевого измерителя при различных значениях SNR приведены на рисунках 5–7.

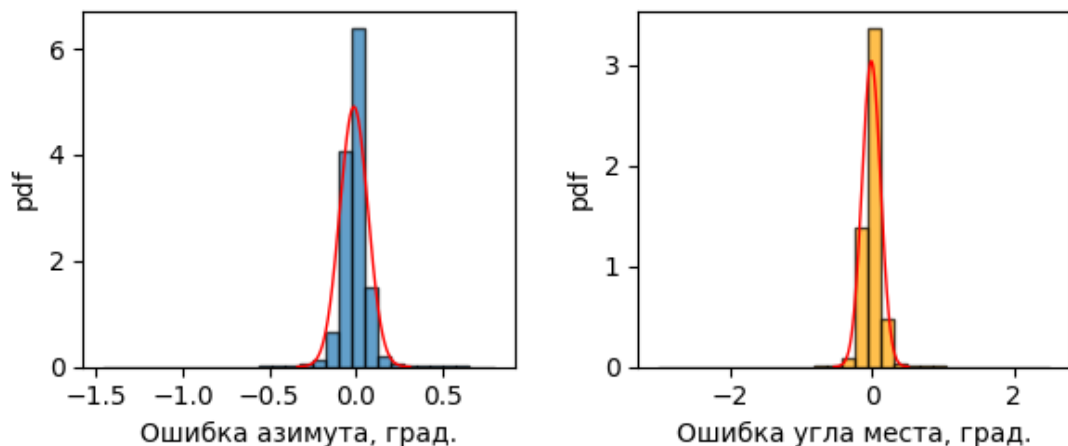


Рисунок 5 – Ошибки при SNR в подрешетке 20 дБ

При отношении сигнал/шум 20 дБ средняя ошибка измерения как по азимуту, так и по углу места составила $-0,01^\circ$, что свидетельствует об отсутствии заметного систематического смещения и о корректной работе обученной модели. Выборочное среднеквадратическое отклонение ошибки по азимуту равно $0,081^\circ$, а по углу места – $0,131^\circ$. Межквартильный размах для азимута составляет $0,072^\circ$, тогда как для угла места он увеличивается до $0,128^\circ$. Ширина распределения, содержащая 90% всех измерений, равна $0,205^\circ$ для азимута и $0,341^\circ$ для угла места. Значения указывает на более высокую точность оценки азимута по сравнению с углом места.

Визуальный анализ распределений показывает, что ошибки имеют форму, близкую к нормальной. Однако значение критерия хи-квадрат Пирсона при моделировании является достаточно большим, что отвергает гипотезу о нормальности распределения ошибок и является характерным для суммарно-разностного пеленгования с нормировкой к мгновенному значению сигнала суммарного канала.

Можно отметить, что при заданной ширине главного лепестка ДН уровень ошибок составляет доли процента. Разброс ошибок по углу места остается больше относительно азимута, что объясняется геометрией антенной системы. Тем не менее даже в этом случае абсолютные значения ошибок остаются малыми и практически не оказывают существенного влияния на итоговую точность пеленгования.




Рисунок 6 – Ошибки при SNR в подрешетке 10 дБ

При отношении сигнал/шум 10 дБ средняя ошибка измерения по азимуту составила $-0,02^\circ$ при выборочном среднеквадратическом отклонении $0,216^\circ$, межквартильном размахе $IQR = 0,218^\circ$ и ширине распределения, содержащей 90% всех измерений, равной $0,661^\circ$. По углу места средняя ошибка также близка к нулю и составляет $-0,02^\circ$, однако разброс существенно выше: СКО достигает $0,528^\circ$, межквартильный размах равен $0,430^\circ$, а 90%-ная ширина распределения увеличивается до $1,313^\circ$. Таким образом, по мере снижения отношения сигнал/шум наблюдается заметное увеличение дисперсии ошибок, особенно выраженное по каналу угла места. Основной массив значений остается сосредоточенным в окрестности нуля, что говорит об отсутствии выраженного систематического смещения.

Сравнение с шириной главного лепестка ДН показывает снижение точности оценивания. Ширина интервала, содержащего 90% измерений, по углу места превышает аналогичное значение по азимуту почти в два раза, что подтверждает снижение точности в этом канале при ухудшении условий наблюдения.




Рисунок 7 – Ошибки при SNR в подрешетке 0 дБ

При отношении сигнал/шум 0 дБ наблюдается заметное ухудшение точностных характеристик по сравнению с более высокими уровнями SNR. Средняя ошибка измерения азимута составляет $-0,06^\circ$ при выборочном среднеквадратическом отклонении $0,499^\circ$, межквартильном размахе $IQR = 0,594^\circ$ и ширине распределения, содержащей 90% всех измерений, равной $1,590^\circ$. По углу места средняя ошибка увеличивается до $-0,16^\circ$, СКО достигает $1,175^\circ$, межквартильный размах составляет $1,312^\circ$, а 90%-ная ширина распределения возрастает до $3,754^\circ$. Таким образом, по сравнению с предыдущими уровнями шумов наблюдается существенный рост как систематической, так и случайной составляющей ошибки, угломестный канал все также деградирует значительно сильнее.

Анализ результатов моделирования для ИНС при SNR 20...0 дБ, показывает закономерное ухудшение точностных характеристик при снижении отношения сигнал/шум, при этом сохраняется ключевое преимущество метода, заключающихся в практически полном отсутствии систематических ошибок. Это подтверждает, что после обучения MLP систематические ошибки практически полностью подавляются и существенно не зависят от уровня шума в рассматриваемом диапазоне.

При этом основное влияние снижения SNR проявляется в росте случайной составляющей ошибки. Для азимута стандартное отклонение увеличивается почти в 6 раз. Для угла места СКО увеличилось почти в девять раз. Аналогичная тенденция наблюдается и по межквартильному размаху: по азимуту IQR увеличивается с $0,072^\circ$ до $0,594^\circ$, а по углу места – с $0,128^\circ$ до $1,312^\circ$, что свидетельствует о существенном

расширении центральной части распределения ошибок. Ширина интервала, содержащего 90% измерений, также возрастает: по азимуту от $0,205^\circ$ до $1,590^\circ$, а по углу места – от $0,341^\circ$ до $3,754^\circ$, что демонстрирует деградацию точности при ухудшении условий наблюдения.

Несмотря на рост разброса, полученные значения СКО остаются сопоставимыми с потенциально достижимыми характеристиками. Согласно оценке по нижней границе Крамера-Рао, теоретические значения СКО составляют $0,32^\circ$ для азимута и $0,74^\circ$ для угла места. Фактически достигнутые значения нейросетевого метода при 0 дБ составляют $0,499^\circ$ и $1,175^\circ$ соответственно, что примерно в 1,5 раза хуже теоретического предела. При более высоких SNR (10 и 20 дБ) фактическая точность приближается к потенциально достижимой, что составляет 0,4...0,7% от ширины главного лепестка диаграммы направленности.

Заключение

Проведенные исследования подтвердили, что применение многослойного перцептрона в составе суммарно-разностного пеленгатора позволяет практически полностью устранить систематические ошибки, вызванные амплитудно-фазочастотными неидентичностями приемных каналов. После обучения нейросети средние ошибки снизились до сотых долей градуса, а среднеквадратическое отклонение и 90-процентная ширина распределения уменьшились в десятки раз, составив от 0,4% до 0,7% от ширины главного лепестка диаграммы направленности. Обученная модель сохраняет работоспособность в широком диапазоне отношений сигнал/шум, существенно отличающемся от условий обучения, причем систематическая ошибка остается близкой к нулю. Достигнутая точность примерно в 1,5 раза превышает теоретический предел Крамера-Рао при низких SNR и приближается к нему при высоких, а дальнейшее увеличение объема выборки или числа эпох обучения не дает значимого улучшения.

Предложенный нейросетевой метод обеспечивает высокую точность пеленгования без необходимости хранения громоздких калибровочных таблиц и может быть рекомендован для применения в радиолокационных системах с цифровыми фазированными антенными решетками, использующих суммарно-разностный метод пеленгации.

Дальнейшие исследования предполагают расширение датасета за счет включения реальных измерений, а также экспериментальную проверку на макете радиолокатора.

Список использованных источников:

1. Ратынский, М. В. Моноимпульсная пеленгация в РЛС с цифровыми ФАР / М. В. Ратынский, В. И. Порсев. М.: Радиотехника, 2019.
2. Skolnik, M. I. Radar Handbook / M. I. Skolnik; 3rd ed. USA: McGraw-Hill, 2008.
3. Козлов, С. В. Пеленгационные антенные системы с пространственной компенсацией помех : учеб.-метод. пособие / С. В. Козлов. – Минск : БГУИР, 2019. – 158 с.
4. Зайцев, И. А. Вариант построения суммарно-разностного пеленгатора на базе антенной решетки с подрешетками с использованием искусственной нейронной сети – в наст. сборнике.

UDC 621.396

RESULTS OF A STUDY ON THE EFFECTIVENESS OF A NEURAL NETWORK METHOD FOR MEASURING ANGULAR COORDINATES FOR A TOTAL-DIFFERENCE DIRECTION FINDER

Zaitsev I.¹, Krivitsky P.¹

Belarusian State University of Informatics and Radioelectronics¹, Minsk, Republic of Belarus

Kozlov S. – Dr. Sci. (Tech.), Professor

Annotation. The results of a study on the effectiveness of a neural network method for measuring angular coordinates in a sum-difference direction finder based on an antenna array with subarrays are presented. The process of dataset generation is considered, including the simulation of receiving channels accounting for amplitude-phase-frequency non-identities, angular scanning, and carrier frequency tuning. An architecture of the measurement unit based on a multilayer perceptron is proposed. Statistical modeling shows that the use of a neural network makes it possible to almost completely eliminate systematic direction-finding errors caused by channel non-identities and to achieve accuracy close to the potentially achievable one.

Keywords. antenna array, subarray, sum-difference direction finder, artificial neural network, multilayer perceptron, dataset, amplitude-phase-frequency non-identities.